

**UNIVERSIDAD NACIONAL DE PIURA**  
**FACULTAD DE CIENCIAS**  
**ESCUELA PROFESIONAL DE ESTADÍSTICA**



**TESIS**

**APLICACIÓN DE LAS REDES NEURONALES PARA DETERMINAR  
LOS PRONÓSTICOS MENSUALES DE LA INFLACIÓN PARA EL  
AÑO 2018.**

**PRESENTADA POR:**

**Bach. JUAN GERARDO ZAPATA LAUREANO**

**PARA OPTAR EL TÍTULO PROFESIONAL DE:**

**LICENCIADO EN ESTADÍSTICA**

**LINEA DE INVESTIGACIÓN:**

**MATEMÁTICAS Y ESTADÍSTICA**

**PIURA – PERU**

**2019**

**UNIVERSIDAD NACIONAL DE PIURA**  
**FACULTAD DE CIENCIAS**  
**ESCUELA PROFESIONAL DE ESTADÍSTICA**

**TESIS**

**APLICACIÓN DE LAS REDES NEURONALES PARA DETERMINAR  
LOS PRONOSTICOS MENSUALES DE LA INFLACIÓN PARA EL  
AÑO 2018.**

**LINEA DE INVESTIGACIÓN:**  
**MATEMÁTICAS Y ESTADISTICA**



---

**Bach. JUAN GERARDO ZAPATA LAUREANO**  
**EJECUTOR**



---

**Dr. CARLOS EDUARDO CABRERA PRIETO**  
**ASESOR**

## DECLARACIÓN JURADA DE ORIGINALIDAD DE LA TESIS

Yo, **JUAN GERARDO ZAPATA LAUREANO**, identificado con DNI N° **72947693**, Bachiller en la Escuela Profesional de **ESTADÍSTICA**, de la Facultad de **CIENCIAS** y domiciliado en Jr. Independencia #206 del Distrito de Catacaos, Provincia de Piura, Departamento de Piura.

Celular: **969950116**, Email: [juanzapatal@hotmail.com](mailto:juanzapatal@hotmail.com).

**DECLARO BAJO JURAMENTO:** que la tesis que presento es original e inédita, no siendo copia parcial ni total de una tesis desarrollada y/o realizada en el Perú o en el extranjero, en caso contrario de resultar falsa la información que proporciono, me sujeto a los alcances de lo establecido en el Art. N° 411, del código Penal concordante con el Art. 32° de la ley N° 27444, y Ley de Procedimiento Administrativo General y las Normas Legales de Protección a los Derechos de Autor.

En fe de lo cual firmo la presente.

Piura, 15 de Octubre de 2019.



**JUAN GERARDO ZAPATA LAUREANO**

**DNI N° 72947693**

**Artículo 411.-** El que, en un procedimiento administrativo, hace una falsa declaración en relación con hechos o circunstancias que le corresponde probar, violando la presunción de veracidad establecida por ley, será reprimido con pena privativa de libertad no menor de uno ni mayor de cuatro años.

**Art. 4 Inciso 4.12 del Reglamento del Registro Nacional de Trabajos de Investigación para optar grados académicos y títulos profesionales – RENATI Resolución de Consejo Directivo N° 033-2016-SUNEDU/CD.**


**UNIVERSIDAD NACIONAL DE PIURA**  
**FACULTAD DE CIENCIAS**  
**ESCUELA PROFESIONAL DE ESTADÍSTICA**

**TESIS**

**APLICACIÓN DE LAS REDES NEURONALES PARA DETERMINAR  
LOS PRONOSTICOS MENSUALES DE LA INFLACIÓN PARA EL  
AÑO 2018.**

**LINEA DE INVESTIGACIÓN:  
MATEMÁTICAS Y ESTADISTICA**

**JURADO DE LA TESIS**



---

**Dr. ANA MARILU LEON SILVA**  
**PRESIDENTE**



---

**M.Sc. MARCOS VICTORIANO QUIROZ CALDERON**  
**SECRETARIO**



---

**Dr. RAMÓN COSME CORREA BECERRA**  
**VOCAL**



# UNIVERSIDAD NACIONAL DE PIURA FACULTAD DE CIENCIAS



"AÑO DE LA LUCHA CONTRA LA CORRUPCIÓN Y LA IMPUNIDAD"

## ACTA DE SUSTENTACIÓN 066-2019-UI-FC-UNP

### FACULTAD DE CIENCIAS

Los Miembros del Jurado Calificador que suscriben, reunidos para evaluar la Tesis denominada **"APLICACIONES DE LAS REDES NEURONALES PARA DETERMINAR LOS PRONÓSTICOS MENSUALES DE LA INFLACIÓN PARA EL AÑO 2018"** presentada por el Señor Bachiller **JUAN GERARDO ZAPATA LAUREANO**, con el asesoramiento del **Dr. Carlos Eduardo Cabrera Prieto**; oídas las observaciones y respuestas a las preguntas formuladas, y de conformidad al Reglamento de Tesis para obtener el Título Profesional en la Facultad de Ciencias, lo declaran:

APROBADO (X)

DESAPROBADO ( )

Con la mención de:

MUY BUENO

(X) En consecuencia, queda en condición de ser ratificado por el Consejo de Facultad de Ciencias de la Universidad Nacional de Piura, y recibir el **TÍTULO PROFESIONAL DE LICENCIADO EN ESTADÍSTICA**.

(X) En consecuencia, queda en condición de ser ratificado por el Consejo Universitario de la Universidad Nacional de Piura, y recibir el **TÍTULO PROFESIONAL DE LICENCIADO EN ESTADÍSTICA**; después que el sustentante incorpore la sugerencia del Jurado Calificador.

Piura, 14 de octubre de 2019.

  
Dra. **ANA MARILÚ LEÓN SILVA**  
PRESIDENTE DE JURADO DE TESIS

  
Lic. **MARCOS VICTORINO QUIROZ CALDERÓN**  
SECRETARIO DE JURADO DE TESIS

  
Dr. **RAMÓN COSME CORREA BECERRA**  
VOCAL DE JURADO DE TESIS



Campus Universitario - Urb. Miraflores S/N. Castilla  
PIURA – PERU

## **DEDICATORIA**

### **“A Dios**

Infinitas gracias por permitirme culminar con éxito esta etapa de mi vida profesional.”

### **"Para mis padres Juan y Pelagía, mi hermana Angeles**

...por su apoyo incondicional y orientándome siempre por el camino correcto.”

### **"A mi esposa Brisset**

... por el tiempo que dejé de pasar con ella y por su aliento constante para realizar este trabajo, siempre positiva.”

### **"A mi hija, Brihanna**

... motivo y energía en cada amanecer, sin buscarlo es mi fortaleza en cada paso.

## **AGRADECIMIENTO**

Expreso mi eterno agradecimiento a los señores docentes de la facultad de Ciencias de la Universidad Nacional de Piura, en especial al Dr. Carlos Eduardo Cabrera Prieto, por su contribución decisiva en mi formación académica de Licenciado en Estadística, por su asesoramiento y orientación profesional para la culminación del presente trabajo e investigación.

A la Universidad Nacional de Piura, por haberme dado las facilidades y la oportunidad de capacitarme dentro de mi formación profesional y así aumentar mis conocimientos para poder ser un instrumento en el desarrollo y progreso del país.

<b>ÍNDICE</b>	<b>Pág.</b>
Índice	vi
Índice de cuadro	vii
Índice de figuras	viii
Resumen	ix
Abstract	x
INTRODUCCIÓN	11
CAPITULO I: PLANTEAMIENTO DEL PROBLEMA	12
1.1 Descripción de la realidad problemática	12
1.2 Identificación y formulación del problema	14
1.3 Objetivos de la Investigación	15
1.3.1 Objetivo general	15
1.3.2 Objetivos específicos	15
1.4 Justificación de la investigación	15
1.5 Alcances de la investigación	16
1.6 Limitaciones de la investigación	17
CAPITULO II: MARCO TEORICO	18
2.1 Antecedentes de la investigación	18
2.1.1 Antecedentes internacionales	18
2.1.2 Antecedentes nacionales	19
2.1.3 Antecedentes locales	20
2.2 Bases teoricas	20
2.2.1 Definición: La Inflación	20
2.2.2 Consecuencias positivas de la inflación	21
2.2.3 Nociones básicas de series de tiempo y predicción	24
2.2.3.1 Definición de series de tiempo	24
2.2.3.2 Objetivo del análisis de series de tiempo	24
2.2.3.3 Componentes de una serie de tiempo	24
2.2.3.4 Métodos de predicción	25
2.2.3.5 Métodos de Box y Jenkins	25
2.3 Redes neuronales	26
2.3.1 Neurona biológicas	26
2.3.2 Redes neuronales artificiales (RNA)	27
2.3.3 Arquitectura de las redes neuronales	29
2.3.4 Neuronas y conexiones	33
	vi



2.3.5 Tipos de aprendizaje básicos	35
2.3.6 Entrenamiento de la red	38
2.3.7 Validación	40
2.3.8 Analisis de las series de tiempo utilizando una red neuronal	41
2.4 Formulación de la hipótesis	42
2.4.1 Hipótesis general	42
2.4.2 Hipótesis específica	42
2.5 Operacionalización de variables e indicadores	42
2.6 Marco conceptual	42
<b>CAPITULO III: MARCO METODOLOGICO</b>	<b>44</b>
3.1 Enfoque y diseño de la investigación	44
3.2 Nivel y tipo de la investigación	44
3.3 Población y muestra de la investigación	44
3.4 Técnicas e instrumentos de investigación	44
3.5 Técnicas para el procesamiento de datos	45
3.6 Metodología para predicción de un modelo univariable con redes neuronales	45
<b>CAPITULO IV: RESULTADOS Y DISCUSIÓN</b>	<b>48</b>
4.1 Serie de la inflación	48
4.1.1 Redes Neuronales	48
4.2 Discusión	55
<b>CAPITULO V: CONCLUSIONES Y RECOMENDACIONES</b>	<b>56</b>
5.1 Conclusiones	56
5.2 Recomendaciones	56
<b>CAPITULO VI: REFERENCIAS BIBLIOGRAFICAS</b>	<b>57</b>
<b>ANEXOS</b>	<b>61</b>
ANEXO 1	61
ANEXO 2	62
ANEXO 3	62

## ÍNDICE DE CUADROS, TABLAS E ILUSTRACIONES

### ÍNDICE DE TABLAS

**Pág.**

Tabla 1 Resumen de procesamiento de casos	48
Tabla 2 Información sobre la red	49
Tabla 3 Resumen del modelo	50
Tabla 4 Resumen del procesamiento de caso	50
Tabla 5 Información sobre la red	51
Tabla 6 Resumen del modelo	51
Tabla 7 Importancia de las variables independientes	54

### ÍNDICE DE FIGURAS

**Pág.**

Figura 1 Neurona biologica	26
Figura 2 Red multicapa	29
Figura 3 Neurona	30
Figura 4 Esquema de una red neurona antes del entrenamiento	33
Figura 5 Conexiones de diferentes pesos sinápticos	34
Figura 6 Neuronas bias y sinápticos	35
Figura 7 Modelo simple formado por tres neuronas	36
Figura 8 Intensificación del peso sináptico	38
Figura 9 Errores de prueba y entrenamiento	40
Figura 10 Gráfico de pronosticados	52
Figura 11 Gráfico de residuos	53
Figura 12 Gráfico de la importancia	54

## RESUMEN

La búsqueda constante del conocimiento, conduce al descubrimiento de nuevas herramientas, que ayudan al ser humano a solucionar problemas reales. En este contexto, aparecen las redes neuronales inspiradas en los sistemas biológicos para resolver diversos problemas, sobre todo aquellos en donde la metodología tradicional tiene ciertas dificultades, como son aquellos sistemas altamente no lineales.

Uno de estos problemas en donde estas herramientas están demostrando gran desempeño, es la estimación de funciones, sobre todo para la realización de pronósticos. La investigación tuvo como objetivo principal construir una red neuronal, para determinar los pronósticos mensuales de la inflación para el año 2018 utilizando la información de enero 2008 a diciembre 2017

La construcción y diseño del modelo o de la red neuronal se hizo con ayuda del programa matemático, MATLAB y de los programas estadísticos SPSS y EVIEWS; estos últimos se utilizaron para el pre procesamiento de los datos, que incluyó el análisis de la no estacionariedad de la serie y de su transformación a serie estacionaria; requisito importante para incrementar la velocidad de convergencia del algoritmo de entrenamiento de la red.

Palabras claves:

Computación evolutiva, redes neuronales, retro propagación

## ABSTRACT

The constant search for knowledge leads to the discovery of new tools that help human beings solve real problems. In this context, neural networks inspired by biological systems appear to solve various problems, especially those where the traditional methodology has certain difficulties, such as those systems that are highly non-linear.

One of these problems where these tools are showing great performance, is the estimation of functions, especially for the realization of forecasts. The main objective of the research was to build a neural network, to determine the monthly forecasts of inflation for the year 2018 using the information from January 2008 to December 2017

The construction and design of the model or the neural network was done with the help of the mathematical program, MATLAB and the statistical programs SPSS and EVIEWS; the latter were used for the pre-processing of the data, which included the analysis of the non-stationarity of the series and its transformation into a stationary series; important requirement to increase the speed of convergence of the training algorithm of the network.

Keywords:

Evolutionary computing, neural networks, retro propagation

## INTRODUCCIÓN

El objetivo de la investigación Diseñar un modelo no lineal para predecir el comportamiento de la inflación.

La inteligencia Artificial ha surgido como una nueva área del conocimiento. Está formada por un conjunto de técnicas que intentan imitar, en forma artificial, las habilidades con la inteligencia humana. Una de estas técnicas que trata de simular el pensamiento humano mediante conexión de neuronas es la denominada Redes Neuronales, utilizada recientemente con un relativo éxito para la predicción de series de tiempo.

La tesis es importante porque muestra la capacidad de las redes neuronales artificiales (RNA) que se ha diseñado para realizar pronósticos en series de tiempo financiera, en particular sobre la serie del futuro de la Inflación, como una herramienta alterna a las técnicas estadísticas tradicionales, como la metodología ARIMA, además de explicar de manera clara y sencilla, pero sin perder de vista la rigurosidad matemática que involucra este tipo de temas, el funcionamiento de una RNA.

Este trabajo, tiene un doble propósito; por un lado pretende llenar ese vacío de conocimiento, proponiendo una nueva metodología para hacer pronósticos, basada en las redes neuronales, y así mismo, servir de base para futuras investigaciones. Las redes neuronales son programas de computadora que intentan simular el comportamiento del cerebro humano, tratando de dar a estos, cierta capacidad de decisión e incluso un cierto grado de “inteligencia”.

El primer capítulo es introductorio, donde se plantea el problema, objetivos, alcances y limitaciones. El segundo capítulo proporciona el marco teórico, que presenta los antecedentes, las bases teóricas, formulación de la hipótesis y el marco conceptual. En el tercer capítulo plantea el tipo de investigación, método y diseño, población y muestra, técnicas e instrumentos de investigación para el procesamiento de datos. En el cuarto capítulo, se dedica a la construcción del modelo de Red Neuronal para la serie de tiempo de la inflación de enero de 2008 a diciembre 2017, se discuten los resultados obtenidos según los criterios establecidos. En el quinto capítulo se plantea las conclusiones, así como algunas recomendaciones para el camino de explorar en esta línea de investigación y por último en el sexto capítulo las fuentes de información.

# **CAPITULO I: ASPECTOS DE LA PROBLEMÁTICA**

## **1.1 DESCRIPCIÓN DE LA REALIDAD PROBLEMÁTICA**

En la década de los ochenta, la economía padeció de hiperinflación, mientras el rendimiento per cápita, y se incrementaba la deuda externa. Ha mediado de los 80s, Perú estaba marginado del apoyo del FMI y del Banco Mundial, debido a sus grandes atrasos en la deuda.

Se incrementó la gasolina en 30 %; el servicio postal y telefónico 20 %; agua potable y alcantarillado 10 %.

Se devalúa el Sol en 12 %; el dólar MUC (moneda única de cambio), se fija en 13.95 intis y el dólar financiero en 17.5 intis por dólar norteamericano. Después de año y medio del gobierno aprista, los desequilibrios macroeconómicos se hacían insostenibles.

El aprismo aplica la política de precios con 4 categorías: los controlados propiamente dichos, los de régimen especial, los regulados y los supervisados.

Ese gobierno siempre recurrió a los recursos del Estado para impulsar un funcionamiento privado a corto plazo compatible con una baja inflación aparente. Después de 2 años de experimento de una política económica improvisada, el gobierno aprista de Alan García fue autodestruyéndose. Las empresas no invirtieron en el país y sólo se limitaron a aumentar la producción y los precios.

A partir del tercer año de ese gobierno o desgobierno vinieron las reacciones de la población frente a los ajustes de los llamados "paquetazos", seguido de las colas que tenían que hacer todos para conseguir una cierta cantidad de productos de primera necesidad como son leche, pan, arroz, azúcar.

A todo eso se sumó la especulación por parte de los comerciantes para proteger su capital.

Desde mayo de 1988 que comenzaron los "paquetazos", los ajustes en la economía nacional se fueron incrementando.

El tipo de cambio subió en 227 % para gran parte de las partidas de importación y se subieron aún más los precios públicos.

A nivel político se observaba una situación crítica y compleja por efecto de las drásticas medidas, la reducción de los ingresos, la estatización de la banca, el incremento de la burocracia.

Los economistas señalaron que se estaba a las puertas de un manejo hiperinflacionario de la economía peruana.

Los efectos de la desastrosa política aprista se mostró no sólo con las colas interminables para conseguir los productos alimenticios, sino que se produjeron huelgas, desabastecimiento, violencia, especulación.

Alan García hizo un anuncio el 19 de Noviembre de 1988, de que se iba a tomar nuevas medidas y que se iba a retirar de la política al finalizar su mandato. Mandó otro paquetazo de ahorcamiento a la población y mintió porque no se retiró de la política.

En los diarios capitalinos sólo se informaba de huelgas, de colas para conseguir cualquier producto. Pequeños empresarios entraban en colapso y las familias sufrían todas las consecuencias.

Los barcos con productos, varados en el puerto se negaban a descargar hasta que no se les pagara. Las divisas se agotaron por el mal uso. Las colas se alargaban y multiplicaban.

El 22 de noviembre de 1988 aparece Sendero Luminoso, iniciando el derrumbe de 32 torres de alta tensión, dejando sin luz a poblaciones desde Chiclayo hasta Marcona.

"La población limeña ha entrado en un estado de shock. La contaminación del agua potable, el avance de la violencia, la falta de electricidad, la ausencia de pan y transportes, las alzas, la crisis política, todo eso condensado en un solo día era demasiado".

Alan García siguió una política egocéntrica, caudillista y un extremado centralismo político. Los analistas de esos años afirmaron que el gobierno aprista dejó al Perú en un colapso.

#### **Otros desastres en cifras**

- Inflación acumulada: 2,178.482 %
- Remuneraciones y consumo per cápita por debajo del 50 %
- El índice de pobreza sólo en Lima Metropolitana ascendió a 43 % 17
- Las reservas internacionales netas del BCRP (Banco Central de Reserva del Perú) cayeron de 894 millones de dólares en Julio de 1985 a 105 millones de dólares a Julio de 1990.
- El nivel del subempleo ascendió a un desastroso 73 % al término del gobierno aprista.
- La producción agrícola nacional cayó ostensiblemente y la importación de productos aumentó un 49 %.
- El número de horas perdidas por conflictos laborales con el gobierno, aumentó de 6 millones en 1985 a 124 millones en 1990.
- El ingreso per cápita cayó en un record, nunca antes visto.
- Como consecuencia del mal manejo del gobierno aprista, el Grupo Andino redujo la inversión en el Perú.
- Durante ese gobierno de Alan García, el Perú apenas recibió inversión extranjera debido a su

desastroso manejo de la economía.

Esto es una breve reseña de lo que se vivió en el Perú a mediados de los años 80s, ya que como principal consecuencia de acuerdo a nuestro tema, fue una inflación de 2,178.482 % considerada una hiperinflación y la más alta a lo largo de la historia peruana y mundial.

Lamentablemente la terrible inflación empobreció y afectó más a la clase proletaria que a cualquier otra; se hizo común el trueque de mercancías ya que los billetes que se tenían en la mañana perdían su valor adquisitivo en la tarde.

Afortunadamente ahora la realidad es distinta, ya que el Perú muestra un gran crecimiento económico.

En el 2006 la inflación anual fue 1,2%, lo que motivó que el BCR no cumpliera la meta de inflación, que había fijado –ya desde hace varios años– en un piso de 1.5% y un techo de 3.5% anual. Como se preveía que en el 2007 la inflación podría ser incluso inferior a la del 2006, el nuevo directorio del BCR prefirió "curarse en salud", lo que hizo bajando el piso y el techo, para el 2007, a 1% y 3%, respectivamente.

Pero sucede que este año la inflación ha repuntado, pues ha sido 1.91% en el I Semestre. Aquí es bueno precisar que estos rangos de inflación son pequeños y nada tienen que hacer con la hiperinflación del primer gobierno de Alan García.

## **1.2 IDENTIFICACIÓN Y FORMULACION DEL PROBLEMA**

El alza de los precios, es sin duda, uno de los temas más importantes y preocupantes en la actualidad; no sólo por el temor de ser el inicio de la inflación incontrolable como años atrás, sino por el impacto que ocasiona en la economía familiar.

Frente a esta progresiva alza de precios, es importante conocer de manera anticipada el comportamiento que puede tener la inflación y en este trabajo se utilizara un método especial para calcularlo, las redes neuronales.

### **1.2.1 Formulación del problema general**

**¿Cuáles serán los valores pronosticados mensuales de la inflación para el periodo Enero-2018 a Diciembre-2018 que se obtendrían utilizando redes neuronales?**



## **1.3 OBJETIVOS**

### **1.3.1 Objetivo general**

Determinar los valores mensuales pronosticados de la inflación utilizando redes neuronales a partir de información histórica contenida del año 2008 al 2017 para valores futuros del periodo Enero-2018 a Diciembre-2018.

### **1.3.2 Objetivos específicos**

- Analizar la base de datos de los valores mensuales de la inflación en el periodo enero-2008 a diciembre-2017, a partir de ellos aplicar el método de pronóstico.
- Someter la serie de tiempo al análisis adecuado para confirmar si satisface los supuestos que se requiere para la aplicación de las redes neuronales, de la suavización exponencial corregida de la tendencia.
- Pronosticar los valores futuros de la inflación para el periodo enero-2018 hasta diciembre-2018 con sus respectivos intervalos de predicción al 95 % para cada uno de ellos.

## **1.4 JUSTIFICACIÓN DE LA INVESTIGACIÓN**

En la actualidad, la caída del precio del dólar, el incremento del costo del barril de petróleo, las lluvias en las zonas de producción agrícola y, en cierta medida, la especulación; vienen alentando un incremento en el costo de los alimentos. Algunos especialistas afirman que este incremento es temporal, en la medida que sus causas vayan desapareciendo; otros, en cambio más pesimistas, confirman que no es una etapa, sino una tendencia económica, originada por la crisis (recesión laboral y productiva) de los Estados Unidos y su influencia en la economía global

A partir de 1985, durante el primer gobierno presidencial de Alan García Pérez, se experimentó un aumento significativo en el precio de la gasolina y agua potable; el encarecimiento de los productos de la canasta familiar, el establecimiento del dólar, las interminables colas para la compra de productos de primera necesidad, sumado a la reducción del 50% en los ingresos familiares; el incumplimiento de pago de la deuda externa y un país que había perdido su calidad de buen pagador ante el mundo. Ello originó una etapa de crisis política y social, generando la desestabilización económica del país, que se tradujo en una tasa de inflación que llegó hasta 7649.6% en el año 1990; la más grande registrada en el país y en los países de la Región sudamericana.

Este proceso de crisis continuó durante varios años, en los que la recaudación tributaria de la SUNAT registraba márgenes de morosidad y evasión de hasta el 75%; impidiendo que el gobierno pueda cumplir en buena medida sus obligaciones internas de pago de trabajadores y de inversión. El uso indiscriminado de los equipos del Banco Central de Reserva para la fabricación de más "intis", la moneda de aquellos años, sin respaldo de oro en las reservas nacionales simplemente aportó en colmar la crisis, generando mayor devaluación de la moneda frente al dólar norteamericano.

A partir de 1990, con el gobierno presidencial de Alberto Fujimori Fujimori, se produjo una medida radical pero necesaria, denominada "shock"; a través de la cual se varió la moneda (hasta entonces el "inti") hacia el "nuevo sol" evitando con ello la mayor devaluación de la moneda, sin embargo esto originó, la reducción de la capacidad de gasto de los ciudadanos, pues desde ese momento 100 (cien) intis del salario de los trabajadores se convertían en 1 (un) nuevo sol. Por otro lado, se inició un proceso de privatización de las empresas del Estado (ENTEL, ENCI, entre otras), cuyos capitales cobrados tendían a garantizar la prestación de servicios a los ciudadanos, la realización de infraestructura y la obtención de recursos para cumplir, o por lo menos, reducir, las obligaciones del Estado.

Los resultados de este largo proceso han permitido que nuestro país se recuperara frente a la inflación vivida del gobierno anterior y reingresando a nuestro país a un estado de viabilidad crediticia.

Lo cierto es que, ni el Perú es tan dependiente como hace 20 años de la economía norteamericana; así como tampoco se ha previsto una política de gobierno coherente con la realidad, dirigida a reducir los impactos "temporales" en la economía familiar, la misma que está conformada por sectores de bajos recursos económicos, para quienes un pequeño incremento es siempre una gran preocupación.

Es por todo lo expuesto que la incertidumbre de los ciudadanos hacia un alza incontrolable de los precios para el año presente, la preocupación del retorno de una economía como la de los años 90s y las expectativas del nuevo gobierno pronto a sumir crecen. Y por ello surge la necesidad de conocer de manera anticipada valores estimados de la inflación para nuestra ciudad, conociendo así el comportamiento que puede tener este indicador durante el año presente, 2018.

## **1.5 ALCANCES DE LA INVESTIGACIÓN**

El trabajo de investigación se focalizo en la realización de un estudio a nivel nacional utilizando para ello investigaciones sobre pronósticos de la inflación de enero de 2008 a diciembre 2017.

En este sentido, es uno de los primeros intentos en aplicar estas herramientas de investigación emergentes, como lo son las “redes neuronales” en la elaboración de pronósticos de la serie de la inflación. Este intento, además permite sentar las bases para nuevas investigaciones sobre pronósticos en otro tipo de empresas o mejorar los ya existentes

## **1.6 LIMITACIONES DE LA INVESTIGACION**

La investigación ha tenido ciertas dificultades en su ejecución:

- Existen pocos estudios realizados por medio de redes neuronales relacionados al presente, y los que existen son aplicados sobre todo a mercado de países desarrollados, por lo que se pretende que este estudio pueda aplicarse a distintas series de tiempo existentes en el mercado.
- La obtención de la información no ha sido fácil por el recelo existente.

## **CAPITULO II: MARCO TEORICO**

### **2.1 ANTECEDENTES DE LA INVESTIGACIÓN**

#### **2.1.1 Antecedentes internacionales**

Pavón (2009) “Inflación y variabilidad de precios relativos” Pontificia Universidad Católica de Chile.

Este trabajo realiza un estudio empírico para la economía chilena, donde se analiza el impacto de la inflación y de la volatilidad de la inflación sobre la variabilidad de los precios relativos (RPV). La muestra se divide en tres períodos para comparar esta relación bajo diferentes escenarios económicos; por ejemplo un período con fijaciones de precios versus otro donde estos fluctúan libremente. Para dilucidar si la experiencia chilena apoya la teoría de costos de ajustes o aquella del mercado con información imperfecta, se descompone la inflación en esperada y no esperada, variables que no habían sido utilizadas en trabajos anteriores para Chile. Los resultados encontrados indican que la inflación impacta positivamente a la RPV, pero en menor magnitud que la volatilidad de la inflación. Por lo tanto es la inestabilidad de la inflación la variable relevante para determinar la variación de precios relativos.

En cuanto a los resultados del impacto de la inflación esperada y no esperada son ambiguos por lo tanto no se puede validar con certeza ninguna de las dos teorías, finalmente en relación a las fijaciones de precios los coeficientes de variabilidad de los precios relativos promedio de todos los bienes son mayores en el período con controles de precios.

Aguirre (2006) “INFLACIÓN ARGENTINA ACTUAL: ANÁLISIS DE LAS CAUSAS, DINÁMICA DE UNA ECONOMÍA EN INFLACIÓN Y DESARROLLO DE OPORTUNIDADES PARA NORMALIZAR SU VALOR” Instituto tecnológico de Buenos Aires Universidad Privada

Este informe analiza el impacto del aumento generalizado en el nivel de precios que sufre el sistema económico argentino actualmente. Parte de una introducción al concepto de inflación, para pasar a luego a un minucioso estudio de las causas que originaron el elevado valor que posee hoy en día el índice de precios al consumidor. Identificadas las causas, se procede a través de la dinámica de sistemas, a modelar al sistema económico que rige actualmente en el país. Esta herramienta permite detectar las principales variables con sus interrelaciones, y visualizar la economía de manera completa. En base al diagrama causal del modelo económico, se analiza sobre el mismo, el impacto que tienen las distintas alternativas para la reducción de la inflación, no sólo sobre dicha variable, sino sobre el resto de las principales variables macro. Luego, y a partir del mencionado análisis, se selecciona la política de estabilización inflacionaria que mejor se adapta a un país con una economía emergente como la Argentina.

### 2.1.2 Antecedentes nacionales

Lavanda (2010) “Determinantes de la inflación: distinguiendo entre choques de demanda y choques de oferta” Universidad Católica del Perú.

El presente trabajo se centra en el estudio y tratamiento del comportamiento del nivel de inflación en el contexto de un régimen de Metas Explícitas de Inflación (MEI)<sup>1</sup> como el adoptado en el Perú desde el año 2002. Si bien el nivel de inflación bajo un régimen de metas inflación puede ser controlado por medio de las bandas y del uso adecuado de los instrumentos de política monetaria, la inflación es una variable económica sensible a diferentes choques, sean estos de demanda o de oferta. Por lo tanto, es importante identificar los componentes que determinan su comportamiento a lo largo del tiempo. La inquietud de identificar los determinantes de la inflación ha sido ampliamente tratada en la literatura empírica internacional. Una muestra de ello es el trabajo de Juselius (2006) aplicado a la economía finlandesa. En dicha investigación se analizan las tres teorías de inflación citadas por Surrey (1989), a 1 Régimen de metas de inflación de ahora en adelante. 2 En un primer momento el Banco Central de Reserva del Perú (BCRP) comprometió el actuar de su política monetaria a una meta de inflación de 2.5% de inflación anual con un margen de tolerancia de un punto porcentual ( $2.5 \pm 1 \%$ ).

A partir del año 2007 el BCRP modificó su meta explícita de inflación; comprometiendo en adelante el actuar de su política monetaria a una meta de una tasa de inflación anual de 2% con un margen de tolerancia de un punto porcentual ( $2 \pm 1 \%$ ). 3 Un choque en el marco de este análisis puede ser entendido como un componente de la inflación que no obedece a cierto actuar de la política monetaria. II saber, la teoría puramente monetaria que indica que la inflación obedece a expansiones en la oferta de dinero; la teoría que sostiene que la inflación es determinada por choques de demanda interna; y la teoría que señala que esta es determinada por choques externos. El análisis empírico de Juselius (2006) hace uso de modelos VAR cointegrados con datos I

Ñamot (2016) “relación entre la tasa der inflación y la tasa de empleo en el Perú: 1995 - 2015”. Universidad Nacional de Trujillo

El presente trabajo de investigación tiene como propósito determinar la relación entre la tasa de desempleo y la tasa de inflación para el Perú; se utilizó datos anuales extraídos del Banco Central de Reserva del Perú y del Instituto Nacional e Informática (INEI) para el periodo 1995 – 2015. Para determinar la relación entre el desempleo e inflación se utilizó la metodología de David F. Hendry, un modelo autoregresivo de rezagos distribuidos, se halló una relación inversa y negativa a largo plazo entre el desempleo y la inflación para el caso peruano.

### **2.1.3 Antecedentes locales**

Julca (2016) "CRECIMIENTO ECONÓMICO Y POBREZA EN EL PERÚ: UN ANÁLISIS DE DATOS DE PANEL PARA EL PERÍODO 2004-2013. Universidad Nacional de Piura.

La presente investigación estudia la relación empírica entre el crecimiento económico regional y la pobreza monetaria, así como la relevancia que este crecimiento tiene sobre la pobreza de las 24 regiones del Perú durante el período 2004-2013, utilizando para su evaluación la metodología de datos de panel. Los resultados permiten corroborar nuestra hipótesis central de que, si bien el crecimiento económico regional de las regiones ha favorecido a la población en situación de pobreza no ha sido suficiente, debido precisamente a la importancia y participación de canales adicionales a este crecimiento, como el gasto social, desempleo, desarrollo financiero e inversión pública productiva, cuyos resultados en la estimación evidencian la significancia de estas variables en materia de reducción de los índices de pobreza. Así también, se evidencia el efecto inverso que tiene el gasto social sobre la pobreza, es decir que un incremento del gasto público total logra contrarrestar la pobreza, y de manera más tangencial cabe precisar que el gasto público en salud y saneamiento es el factor que ha contribuido principalmente en la reducción de la pobreza mientras que el gasto público en educación presenta un coeficiente positivo lo que indica que este gasto incrementa la pobreza en lugar de reducirla al igual que sucede con la tasa de desempleo. De otra parte, el escenario que presenta el desarrollo financiero y la inversión pública productiva sobre la pobreza, permite constatar que ante un incremento de estas variables se logra una reducción de la pobreza, empero, el análisis de cada componente de la inversión evidencia que es la inversión en transporte quien contribuye en mayor medida a la reducción de la pobreza. En efecto podemos decir que la situación del país está mejorando en términos de crecimiento pero que sin embargo persisten ciertas desigualdades regionales que deben ser superadas en términos de pobreza.

## **2.2 BASES TEÓRICAS**

### **2.2.1 Definición**

Del latín inflatio, el término inflación hace referencia a la acción y efecto de inflar. La utilización más habitual del concepto tiene un sentido económico: la inflación es, en este caso, la elevación sostenida de los precios que tiene efectos negativos para la economía de un país.

Esto quiere decir que, con la inflación, suben los precios de los bienes y servicios, lo que genera una caída del poder adquisitivo. Por ejemplo: un trabajador solía comprar 30 kilogramos de alimentos con su salario de 1.000 soles. A los pocos meses, ante la inflación existente, ese mismo salario le permite comprar apenas 10 kilos de alimentos.

Este fenómeno puede originarse por motivos muy diferentes; veamos tres casos a continuación:

- La inflación de demanda, se produce cuando aumenta la demanda general y el sector productivo no está en condiciones de adaptar su oferta, lo que provoca que los precios suban;
- La inflación de costos, por su parte, aparece cuando aumentan los costos de los productores (ya sea por mano de obra, materias primas o impuestos) y éstos, para mantener los beneficios, trasladan el aumento a precios;
- La inflación auto construida, por último, tiene lugar cuando los productores prevén aumentos de precios en el futuro y deciden anticiparse con un ajuste en su conducta actual.
- Asimismo, existen diversos tipos de inflación, tales como:
  - Inflación moderada: los precios suben de manera gradual.
  - Inflación galopante: los precios suben en tasa de dos o tres dígitos en un año.
- Hiperinflación: la subida de los precios puede alcanzar el 1000% anual, lo que refleja una seria crisis económica que provoca que el dinero de un país pierda su valor.

### **2.2.2 Consecuencias positivas de la inflación**

Si bien este término suele evocar épocas de crisis económica y desesperación por parte de los ciudadanos ante el aumento aparentemente imparable de los precios, la inflación también acarrea una serie de fenómenos positivos.

Según el **keynesianismo** (una teoría económica), los salarios nominales tardan menos en incrementarse que en ajustarse hacia el descenso; cuando éstos son sobrevaluados, dicha

particularidad puede llevar a un desequilibrio que dure mucho tiempo, lo cual resulta en un gran porcentaje de desempleo. Teniendo en cuenta que la inflación no superaría los salarios reales si los nominales no cambiaran, los keynesianos aseguran que, en cierta medida, **la inflación puede ayudar a los mercados de trabajo a equilibrarse más velozmente.**

Uno de los medios más comunes para **controlar la oferta de dinero** es la posibilidad de establecer una tasa fija de descuento, la que los bancos deben usar para solicitar un préstamo al banco central; por otro lado, también se pueden realizar operaciones de mercado abierto, o sea que el banco central intervenga en el mercado de bonos para impactar en las tasas de interés nominal. Cuando una economía está atravesando una crisis y ve una baja en su interés nominal, llega un punto en el cual el banco no puede reducir más las tasas, dado que se convertirían en números negativos, y este fenómeno se denomina trampa de liquidez. Nuevamente, un cierto grado de inflación suele asegurar que dichos valores no se acerquen al cero, ofreciendo a las entidades bancarias la posibilidad de reducirlos cuando así lo necesiten.

Como demuestra la historia de ciertos países, un alto grado de inflación puede desembocar en una veloz expansión económica. Una de las razones para esto es que las inversiones de tipo financiero ven su rentabilidad neta (que se obtiene restando al interés nominal la inflación) decrecer considerablemente, lo cual vuelve más tentadoras las inversiones no financieras. Más aún, es importante notar que las medidas de tipo anti inflacionista han demostrado en más de un caso afectar negativamente la economía, como se puede apreciar en el decaimiento que sufrió Brasil en el año 96 y Sudáfrica en el 94.

La inflación es el aumento generalizado y sostenido de los precios de bienes y servicios en un país. Para medir el crecimiento de la inflación se utilizan índices, que reflejan el crecimiento porcentual de una canasta de bienes ponderada. El índice de medición de la inflación es el Índice de Precios al Consumidor (IPC) que en México se le llama INPC (Índice Nacional de Precios al Consumidor). Este índice mide el porcentaje de incremento en los precios de una canasta básica de productos y servicios que adquiere un consumidor típico en el país.

Existen otros índices, como el Índice de Precios al Productor, que mide el crecimiento de precios de las materias primas.



## **Causas de la Inflación**

Existen tres tipos de inflación:

- Inflación por consumo o demanda. Esta inflación obedece a la ley de la oferta y la demanda. Si la demanda de bienes excede la capacidad de producción o importación de bienes, los precios tienden a aumentar.
- Inflación por costos. Esta inflación ocurre cuando el precio de las materias primas (cobre, petróleo, energía, etc.) aumenta, lo que hace que el productor, buscando mantener su margen de ganancia, incremente sus precios.
- Inflación autoconstruida. Esta inflación ocurre cuando se provee un fuerte incremento futuro de precios, y entonces se comienzan a ajustar éstos desde antes para que el aumento sea gradual.
- Inflación generada por expectativas de inflación (circulo vicioso). Esto es típico en países con alta inflación donde los trabajadores piden aumentos de salarios para contrarrestar los efectos inflacionarios, lo cual da pie al aumento en los precios por parte de los empresarios, originando un círculo vicioso de inflación

## **¿Cómo se detiene la inflación?**

Para detener la inflación, los bancos centrales tienden a incrementar la tasa de interés de la deuda pública. De esta manera se incrementan las tasas de interés en los préstamos al consumo (tarjetas de crédito, hipotecas, etc.). Al aumentar las tasas de interés del consumo, se frena la demanda de productos.

El lado negativo de este control es que al frenar la demanda de productos, se frena a la industria que los produce, lo cual puede llevar a un estancamiento económico y desempleo. Un ejemplo es el sexenio del Presidente Vicente Fox, durante el cual se controló la inflación (el tercer mejor sexenio, después de los gobiernos de Adolfo López Mateos y Gustavo Díaz Ordaz), pero el crecimiento del Producto Interno Bruto ha sido de los peores en 70 años, sólo por encima de Miguel de la Madrid Hurtado.

## **2.2.3 Nociones básicas de series de tiempo y predicción**

### **2.2.3.1 Definición de Serie de Tiempo**

De acuerdo a Bowerman y O'Connel, (1993), una serie de tiempo es una secuencia cronológica de observaciones de una variable particular.

Conseguimos series de tiempo en los distintos campos del saber: en economía, mercadeo, demografía, meteorología, ingeniería, etc. Muchos son los ejemplos de series de tiempo que podrían citarse, tales como:

- Las ventas mensuales de una empresa en la última década.
- El número de automóviles producidos por año de determinada marca en el periodo 1985-2000.
- La temperatura diaria promedio de los últimos 6 meses.

### **2.2.3.2. Objetivos del Análisis de Series de Tiempo**

Según Chatfield (1978), son varios los objetivos por los cuales se puede querer analizar una serie de tiempo.

### **2.2.3.3 Componentes de una serie de tiempo**

- Descripción: Cuando tenemos una serie de tiempo, el primer paso en el análisis es graficar los datos y obtener medidas descriptivas simples de las propiedades principales de la serie.
- Explicación: Cuando las observaciones son tomadas sobre dos o más variables, es posible usar la variación en una serie para explicar la variación en otras series.
- Predicción: Dada una serie de tiempo se puede querer predecir los valores futuros de la serie. Este es el objetivo más frecuente en el análisis de series de tiempo.
- Control: Cuando una serie de tiempo se generan por mediciones de calidad de un proceso, el objetivo del análisis puede ser el control del proceso.

Una serie de tiempo frecuentemente es examinada con la intención de descubrir patrones históricos que puedan ser útiles en la predicción. Para identificar estos patrones es conveniente pensar que una serie de tiempo consiste de varios componentes (Bowerman y O'Conell, 1993):

1. Tendencia: Una serie de tiempo tiene tendencia cuando por largos periodos los valores crecen o decrecen. También puede definirse como cambios en la media.
2. Ciclos: Se refiere a movimientos hacia arriba y hacia abajo alrededor del nivel de la tendencia. Estas fluctuaciones, medidas de pico a pico, pueden tener una duración larga.

3. Variaciones Estacionales: Son patrones periódicos que ocurren y se repiten cada determinado tiempo, por ejemplo: anualmente. Estas variaciones son usualmente causadas por factores como el clima y las costumbres.

4. Fluctuaciones Irregulares: Son movimientos erráticos en una serie de tiempo que no siguen un patrón regular, ni reconocible. Tales movimientos presentan “lo que queda” en una serie de tiempo después de que la tendencia. Ciclos y variaciones estacionales han sido explicadas.

#### **2.2.3.4 Métodos de Predicción**

Pueden obtenerse valores futuros de una serie de tiempo observada mediante una gran variedad de métodos de predicción. Estos métodos pueden clasificarse fundamentalmente en tres tipos:

1. Subjetivo: Las predicciones se hacen sobre bases subjetivas usando el criterio, la intuición, el conocimiento en el área y otra información relevante (Chatfield, 1978). Entre estos métodos están: Ajuste de una curva subjetiva, el Método Delphi y comparaciones tecnológicas en tiempo independiente. Ninguno de estos métodos se consideren es este estudio.

2. Univariado: Este tipo de método obtiene valores futuros de la serie basándose en el análisis de sus valores pasados, se intenta conseguir un patrón de éstos datos, se asume que este patrón continuará en el futuro y se extrapola para conseguir tales predicciones. Son muchos los métodos que encajan en esta categoría, entre éstos se encuentran: Extrapolación de curvas de tendencia, suavización exponencial, método de Holt-Winters y método de Box y Jenkins (ARIMA). Este último es un método ampliamente utilizado y es el que centraremos nuestro interés.

3. Causal o Multivariado: Involucra la identificación de otras variables que están relacionadas con la variable a predecir. Una vez que esas variables han sido identificadas, se desarrolla un modelo estadístico que describe la relación entre esas variables y la variable a predecir. La relación estadística derivada es usada entonces para predecir la variable de interés (Bowerman y O’Connell, 1993). Entre estos métodos están: Regresión múltiple, modelos econométricos y método de Box y Jenkins (Modelo de Función de Transferencia).

Este último método es una extensión del modelo ARIMA que consiste en describir la relación entre la variable de entrada y la variable de salida. Aunque el método puede generalizarse para varias variables de entrada, nos concentramos únicamente en el caso bivariable (una variable de entrada y una de salida).

#### **2.2.3.5 Métodos de Box y Jenkins**

Se estudiarán dos metodologías desarrolladas por Box y Jenkins que permiten predecir valores futuros de una serie de tiempo basándose en valores pasados de una sola variable o dos variables entre las que existe una relación causal.

## 2.3 REDES NEURONALES

### 2.3.1 Neuronas Biológicas

El cerebro humano está conformado por millones de neuronas, que se interconectan formando una “Red Neuronal”. Estas, continuamente reciben señales de entrada de muchas fuentes (millones de instrucciones), las procesan y emiten una respuesta que permiten la vida normal del ser humano.

Las neuronas son las células que forman la corteza cerebral de los seres vivos y cada una está formada por tres elementos: el cuerpo, axón y dendritas, como se observa en la figura 2.1.




Figura 1. Neurona biológica

Las dendritas forman una estructura de filamentos muy fina que rodean el cuerpo de la neurona. El Axón, es un tubo delgado y largo que se ramifica en su extremo en pequeños bulbos finales que casi tocan las dendritas de las células vecinas. La pequeña separación entre los bulbos finales y las dendritas se le denomina sinápsis. Las neuronas, en forma muy similar a las demás células del cuerpo, funcionan a través de impulsos eléctricos y reacciones químicas. Los impulsos eléctricos que utiliza una neurona para intercambiar información con las demás, viajan por el axón, que hace contacto con las dendritas de la neurona vecina mediante la sinápsis. La intensidad de la corriente transmitida depende de la eficiencia de la transmisión sináptica. Una neurona en especial, transmitirá un impulso eléctrico por su axón, si hay suficientes señales de las neuronas vecinas que transmiten en un tiempo corto a través de sus dendritas. La señal que se transmite a la neurona, podrá ser además, ya sea inhibitoria o excitatoria. La neurona dispara, esto es, manda el impulso por su axón, si la excitación excede su inhibición por un valor crítico, el umbral de la neurona.

### 2.3.2 Redes neuronales artificiales (RNA)

Las redes neuronales artificiales o RNA nacen de la necesidad de crear sistemas que trabajen igual que el cerebro humano, es decir que tengan la capacidad de poder adaptarse ante cualquier situación que se presente en la vida real, situaciones que el ser humano puede reconocer y manejar; por ejemplo reconocer a una persona o cosas o adaptarse a un timbre de voz humana nuevo, reconocer daños físicos, etc.

#### Características

Las RNA tienen varias características que permiten identificarlas, entre las cuales tenemos [1]:

- Dos fases de operación.

1. Entrenamiento de la red. El usuario proporciona a la red un número "adecuado" de estímulos de entrada, y de salida, la red entonces ajusta sus pesos de interconexión o sinapsis hasta que la salida de la red está "lo suficientemente cerca" de la salida correcta.

2. Recuperación de lo aprendido. A la red se le presenta un conjunto de estímulos de entrada y esta simplemente calcula su salida. Cuando la red emplea entrenamiento no supervisado, algunas veces será necesario que reajuste sus sinapsis durante la fase de recuperación.

- No son algorítmicas

Las RNA no se programan mediante una serie predefinida de instrucciones que deben seguir, las RNA generan sus propias "reglas", para asociar la respuesta a su entrada; es decir, aprende por ejemplos y de sus propios errores.

- Requieren de algún tipo de patrón

Como las RNA aprenden de sí mismas y de lo que el ser humano le diga, las RNA necesitan de información inicial para poder realizar la tarea para la que se diseñó.

Las RNA son ideales para dar solución a problemas que no requieren de respuestas precisas, sino de respuestas rápidas y convincentes tales como en el área de reconocimiento cuando se desea saber si ¿se parece? o si ¿es el mismo pero tienen una ligera modificación?

En cuanto a la solución de cálculos precisos, procesamiento en serie o cualquier cosa que no tenga un patrón, las RNA no son buenas.

- Dos tipos de aprendizaje

1. Supervisado.- Se da cuando se proporciona a la red la entrada y la salida correcta, y la red ajusta sus pesos tratando de minimizar el error de su salida calculada. Este tipo de entrenamiento se aplica por ejemplo, en el reconocimiento de patrones.

2. No supervisado.- Se presenta cuando se proporciona a la red únicamente los estímulos, y la red ajusta sus interconexiones basándose únicamente en sus estímulos y la salida de la propia red.

La ley de aprendizaje adecuada se determina en base a la naturaleza del problema que se intenta resolver.

### **Comparación entre redes neuronales e inteligencia artificial**

Las RNA por su características necesitan de información inicial y de patrones para poder funcionar, y una vez dado esta información, las RNA crean sus propias reglas y aprenden de su propia experiencia y errores, sin necesidad de la continua presencia del programador para indicarles lo que deben hacer, siendo una característica muy especial, que las RNA no dan precisión en sus respuestas, sino que dan respuestas o soluciones aproximadas a las necesitadas, mientras que la inteligencia Artificial, depende de información más detallada, (específicamente información aplicada para cierto problema que se desea solucionar), la misma que tiene que ser debidamente considerada y analizada.

En la Inteligencia Artificial, se usan los algoritmos genéticos, sistemas expertos, programación evolutiva; los cuales necesitan de reglas e bases de conocimientos especificados al detalle por parte de los programadores. La inteligencia artificial exige precisión en sus respuestas o soluciones.

### **Comparación entre redes neuronales y la estadística**

Con el inicio de la computación iniciaron a desarrollar software que solucione problemas convencionales o específicos e investigativos, es así que ésta evolución se implementó en la

estadísticas, las personas necesitaban optimizar sus resultados y abaratar costos al mismo tiempo, las ideas se plasmaron e identificaron la importancia aplicación de redes neuronales. La estimación del comportamiento futuro de algunas variables puede realizarse utilizando diversas técnicas de pronóstico.

### 2.3.3 Arquitectura de las Redes Neuronales

Una red neural, relaciona un conjunto de variables de entrada o inputs (independientes)  $\{x_i\}$ ,  $i = 1, \dots, k$ , a un conjunto de una o más variables de objetivo u outputs (dependientes)  $\{y_j\}$ ,  $j = 1, \dots, k$ . La diferencia entre una red neural y los otros métodos de pronóstico, es que, ésta hace uso de una o más capas ocultas, en las cuales las variables de entrada son transformadas por alguna función especial, denominada función de salida o de transferencia. Mientras esta aproximación de capa oculta parece esotérica, representa una forma muy eficiente para modelar procesos estadísticos altamente no lineales.

La figura siguiente, muestra un esquema de una red neuronal:


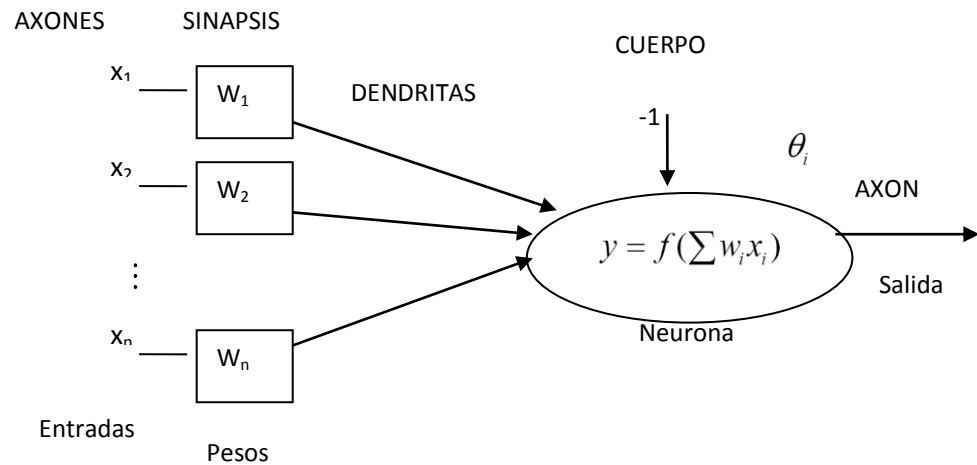


Figura 2. Red multicapa



**Figura 3. Neurona**

En la figura 1.2, se muestra una red neuronal artificial típica, caracterizada por neuronas interconectadas y arregladas en tres capas (aunque esto último puede variar). La información fluye por medio de la “capa de entrada”, pasa a través de la “capa oculta” y se emite por la “capa de salida”. La figura 1.3 muestra una unidad neuronal típica sugerida por McCulloch y Pitts (1943). En ella se pueden distinguir las siguientes componentes: un conjunto de conexiones de entrada, un conjunto de pesos, una función procesadora, un umbral de activación y un valor de salida.

### Modelo

El modelo de Perceptrón multicapa es uno de los modelos de aplicación utilizados en la estadística además utilizan el backpropagation.

### Aplicación

Los modelos de series de tiempo (método estadístico) aplicado a la medición de valores de una variable en el tiempo a intervalos espaciados uniformemente.

Se aplicó en cuestiones como la predicción, la clasificación del riesgo y la selección de información dispersa en los mercados. Para proyecciones y análisis estadísticos.

Las redes neuronales, también llamadas "redes de neuronas artificiales", son modelos bastante simplificados de las redes de neuronas que forman el cerebro. Y, al igual que este, intentan "**aprender**" a partir de los datos que se le suministran.



Así, las principales características que diferencian a las redes neuronales de otras tecnologías de IA son:

- Su capacidad de **aprendizaje** a partir de la experiencia (entrenamiento). Normalmente, para la elaboración de un programa informático es necesario un estudio detallado de la tarea a realizar para después codificarla en un lenguaje de programación. Pero, las redes neuronales pueden ser entrenadas para realizar una determinada tarea sin necesidad de un estudio a fondo ni programarla usando un lenguaje de programación. Además; las redes neuronales pueden volver a entrenarse para ajustarse a nuevas necesidades de la tarea que realizan, sin tenerse que reescribir o revisar el código (cosa frecuente en programas tradicionales).
- Su **velocidad** de respuesta una vez concluido el entrenamiento. Se comportan también en este caso de manera similar a como lo hace el cerebro: los seres humanos no necesitamos pensar mucho para identificar un objeto, una palabra, una vez hemos aprendido a hacerlo.
- Su **robustez**, en el sentido de que el conocimiento adquirido se encuentra repartido por toda la red, de forma que si se lesiona una parte se continúa generando cierto número de respuestas correctas (en este caso también hay cierta analogía con los cerebros parcialmente dañados).

#### **Aplicaciones de las redes neuronales:**

Las características de las redes neuronales hacen que sus posibles aplicaciones sean muy amplias.

Algunas de las aplicaciones más destacadas son:

- Reconocimiento de patrones de clasificación:
  - Reconocimiento de voz, de caracteres manuscritos,...
  - Análisis y reconocimiento de imágenes, formas,...
  - Diagnóstico clínico.
- Análisis de series temporales y predicción:
  - Modelos meteorológicos.

- Predicción del comportamiento.
- Predicción de series temporales.
  - Robótica
  - Etc.

Se ven así las amplias posibilidades que permite esta tecnología, ya al alcance de cualquier programador.

### **Implementación en aplicaciones:**

A la hora de implementar una red neuronal como parte de un programa o sistema informático, se pueden distinguir 3 fases básicas:

- **Diseño:** en esta fase se elige el tipo de red neuronal a usar (la arquitectura o topología), el número de neuronas que la compondrán,...
- **Entrenamiento:** en esta fase se le presentan a la red neuronal una serie de datos de entrada y datos de salida (resultados), para que a partir de ellos pueda aprender.
- **Uso:** se le suministran las entradas pertinentes a la red, y esta genera las salidas en función de lo que ha aprendido en la fase de entrenamiento.

### **Funcionamiento básico:**

Las redes neuronales están formadas por un conjunto de **neuronas artificiales** interconectadas.

Las neuronas de la red se encuentran distribuidas en diferentes **capas** de neuronas, de manera que las neuronas de una capa están conectadas con las neuronas de la capa siguiente, a las que pueden enviar información.

La arquitectura más usada en la actualidad de una red neuronal (como la presentada en la **figura 4**) consistiría en:

- Una primera capa de entradas, que recibe información del exterior.
- Una serie de capas ocultas (intermedias), encargadas de realizar el trabajo de la red.
- Una capa de salidas, que proporciona el resultado del trabajo de la red al exterior.

El número de capas intermedias y el número de neuronas de cada capa dependerá del tipo de aplicación al que se vaya a destinar la red neuronal.




Figura 4. Esquema de una red neuronal antes del entrenamiento. Los círculos representan neuronas, mientras las flechas representan conexiones entre las neuronas.

#### 2.3.4 Neuronas y conexiones

Cada neurona de la red es una **unidad de procesamiento** de información; es decir, recibe información a través de las conexiones con las neuronas de la capa anterior, procesa la información, y emite el resultado a través de sus conexiones con las neuronas de la capa siguiente, siempre y cuando dicho resultado supere un valor "umbral".

En una red neuronal ya entrenada, las conexiones entre neuronas tienen un determinado peso ("peso sináptico").

Un ejemplo de una neurona sobre la que convergen conexiones de diferente peso sináptico ( $W_i$ ) sería el de la **figura 5**:




Figura 5. 3 conexiones de diferente peso sináptico ( $W_1 > W_2 > W_3$ ), convergen sobre la misma neurona Y.

El procesamiento de la información llevado a cabo por cada neurona Y, consiste en una función (F) que opera con los valores recibidos desde las neuronas de la capa anterior ( $X_i$ , generalmente 0 o 1), y que tiene en cuenta el peso sináptico de la conexión por la que se recibieron dichos valores ( $W_i$ ). Así, una neurona dará más importancia a la información que le llegue por una conexión de peso mayor que no a aquella que le llegue por una conexión de menor peso sináptico.

Un modelo simple de la función F seria:

$$F = X_1W_1 + X_2W_2 + \dots + X_iW_i$$


Si el resultado de la función F es mayor que el valor umbral (U), la neurona se activa y emite una señal (1) hacia las neuronas de la capa siguiente. Pero, si por el contrario, el resultado es menor que el valor umbral, la neurona permanece inactiva (0) y no envía ninguna señal:

$$X_1W_1 + X_2W_2 + \dots + X_iW_i \leq U \leftrightarrow \text{Inactivación} \leftrightarrow Y = 0$$

$$X_1W_1 + X_2W_2 + \dots + X_iW_i > U \leftrightarrow \text{Activación} \leftrightarrow Y = 1$$

De esta forma, definido un conjunto inicial de pesos en las conexiones, al presentar un "estímulo" (conjunto de ceros y unos que representa un dato, perfil u objeto) a la capa de entradas, cada neurona en cada capa realiza la operación descrita anteriormente, activándose o no, de manera que al final del proceso las neuronas de la capa de salidas generan un resultado (otro conjunto de ceros y unos), que puede coincidir o no con el que se desea asociar el estímulo.

En el entrenamiento de una red neuronal tanto el peso sináptico de las conexiones como el valor umbral para cada neurona se modifican (según un algoritmo de aprendizaje),



**Figura 6. Neurona bias y su peso sináptico asociado ( $-W_0$ ), en sustitución del valor umbral.**

Con el fin de que los resultados generados por la red coincidan con (o aproximen a) los resultados esperados.

Y para simplificar el sistema de entrenamiento, el valor umbral (U) pasa a expresarse como un peso sináptico más ( $-W_0$ ), pero asociado a una neurona siempre activa ( $X_0$ ). Esta neurona siempre activa, se denomina "bias", y se sitúa en la capa anterior a la neurona Y, tal como se muestra en la **figura 6**.

Así, la condición de activación puede reescribirse como:

$$\underline{X_0W_0} + X_1W_1 + X_2W_2 + \dots + X_iW_i > 0 \Leftrightarrow \text{Activación} \Leftrightarrow Y = 1$$

De esta manera el algoritmo de aprendizaje puede ajustar el umbral como si ajustara un peso sináptico más.

### 2.3.5 Tipos de aprendizaje básicos

Para poder aprender, las redes neuronales se sirven de un algoritmo de aprendizaje.

Estos algoritmos están formados por un conjunto de reglas que permiten a la red neuronal aprender (a partir de los datos que se le suministran), mediante la modificación de los pesos sinápticos de las conexiones entre las neuronas (recordar que el umbral de cada neurona se modificará como si fuera un peso sináptico más).

Generalmente los datos que se usan para entrenar la red se le suministran de manera aleatoria y secuencial.

Los tipos de aprendizaje pueden dividirse básicamente en tres, atendiendo ha como esta guiado este aprendizaje:

- **Aprendizaje supervisado:** se introducen unos valores de entrada a la red, y los valores de salida generados por esta se comparan con los valores de salida correctos. Si hay diferencias, se ajusta la red en consecuencia.
- **Aprendizaje de refuerzo:** se introducen valores de entrada, y lo único que se le indica a la red si las salidas que ha generado son correctas o incorrectas.
- **Aprendizaje no supervisado:** no existe ningún tipo de guía. De esta manera lo único que puede hacer la red es reconocer patrones en los datos de entrada y crear categorías a partir de estos patrones. Así cuando se le entre algún dato, después del entrenamiento, la red será capaz de clasificarlo e indicará en que categoría lo ha clasificado


### Un modelo simple de red neuronal:

Consideremos una red neuronal formada por 2 capas:

- Una **capa de entradas** formada por 2 neuronas: **1** y **2**.
- Una **capa de salidas** formada por una sola neurona: **3**.

Las conexiones entre las dos neuronas de entrada y la neurona de salida presentan pesos sinápticos ajustables mediante el entrenamiento. Y a su vez, el valor umbral (U) de la neurona 3 puede ser ajustado como un peso sináptico más, al considerar  $U = -W_0$  asociado a una neurona más (siempre activa:  $X_0 = 1$ ).

El esquema de este modelo sería el presentado en la **figura 7**:



**Figura 7. Modelo simple, formado por tres neuronas (1,2 y3), más una neurobias.**

Y la condición de activación de la neurona 3 sería:

$$X_0W_0 + X_1W_1 + X_2W_2 > 0 \Leftrightarrow \text{Activación}$$

Además, en este modelo, cada neurona de una capa "transmite" su estado de activación (0 o 1) a la siguiente capa de neuronas, y después deja de estar activa.

Ahora, entrenaremos la red de manera que la neurona 3 se active sólo si las neuronas 1 y 2 están activas, y permanezca inactiva en caso contrario. Hay así cuatro posibles casos.

	$X_1$	$X_2$	Capa de salida ( $X_3$ )
<b>Caso 1</b>	0	0	0
<b>Caso 2</b>	0	1	0


<b>Caso 3</b>	1	0	0
<b>Caso 4</b>	1	1	1

Para entrenar esta red, usaremos una regla de aprendizaje derivada del método de aprendizaje Hebbiano.

### Regla de aprendizaje de Hebb:

También llamada aprendizaje de coincidencia o aprendizaje Hebbiano. Y fue sugerida por Donald Hebb en 1949, a partir de estudios con neuronas reales.

Hebb observó que la sinapsis (conexión entre 2 neuronas reales) se reforzaba sí la neurona de entrada (o presináptica) y la neurona de salida (o postsináptica) eran activadas de manera continua. De esta forma, las conexiones que se usan son las que se refuerzan.



**Figura 8. Intensificación del peso sináptico entre dos neuronas activas.**

Así, según este método de aprendizaje aplicado a las redes neuronales artificiales, las conexiones entre las neuronas de entrada activas y las neuronas de salida activas se refuerzan durante el entrenamiento: coincidencias entre actividad de entrada y actividad de salida se intensifican. Mientras que las conexiones entre neuronas de entrada inactivas y neuronas de salida (activas o inactivas) no se refuerzan.

Este método de aprendizaje puede ser tanto supervisado como no supervisado. Cuando es supervisado, la respuesta correcta para el dato de entrada es introducida para cada neurona de salida, y los pesos sinápticos entre las neuronas activas se incrementan, mientras que los pesos entre neuronas que no estén activas simultáneamente permanecen igual que estaban.

El problema de este método es que no tiene en cuenta la eficacia de la red. Así, aunque la red ya está entrenada y los valores de entrada generen valores de salida correctos, la regla de aprendizaje continua incrementando los pesos sinápticos entre neuronas activas.

### 2.3.6 Entrenamiento de la red

Debido al problema de la regla de aprendizaje de Hebb, usaremos una regla de aprendizaje derivada, y que si tenga en cuenta la eficacia de la red en cada momento:

1. Si la salida generada por la neurona 3 (para los valores de las otras dos neuronas) es la correcta, **no** se realizan ajustes de los pesos sinápticos.
2. Si la salida es **1** pero debería ser **0**, se **reducen** sólo los pesos de las conexiones activas según una constante **C**.
3. Si la salida es **0** pero debería ser **1**, entonces se **aumentan** sólo los pesos de las conexiones activas según la misma constante **C**.

Así, en cada ciclo de entrenamiento:

- Se presenta un dato de entrada (formado por los valores de las neuronas 1 y 2) del conjunto de datos de entrenamiento.
- La red, a partir del dato de entrada generará un dato de salida.
- Se aplica la regla anterior, que mide la eficiencia de la red y actúa en consecuencia.

Y se realizan diferentes ciclos de entrenamiento con los valores de entrenamiento hasta que la red responda correctamente a todos los datos de entrada (en todos los casos de entrenamiento) o hasta que la red ya no pueda aprender más.

De esta forma, si partimos de unos pesos sinápticos iguales a 0 ( $W_1 = W_2 = W_0 = 0$ ) y de una constante de refuerzo igual a 1 ( $C = 1$ ):

- Introducimos el dato de entrada del **caso 1**:  $(X_1, X_2) = (0, 0)$ .
- Puesto que todos los pesos valen 0:  $X_0W_0 + X_1W_1 + X_2W_2 = 0 \Leftrightarrow \text{Inactivación}$
- Así el valor de salida de la neurona 3 es 0, y como el valor de la neurona 3 tenía que ser 0 (según el caso 1 de entrenamiento), no se realizan ajustes de los pesos.
- Introducimos el dato de entrada del **caso 4**:  $(X_1, X_2) = (1, 1)$ .
- Puesto que todos los pesos valen 0:  $X_0W_0 + X_1W_1 + X_2W_2 = 0 \Leftrightarrow \text{Inactivación}$
- Pero, como el valor de salida de la neurona 3 es 0, y tenía que ser 1 (según el caso 4 de entrenamiento), los pesos de las conexiones activas se aumentan en un valor de C (tal



como indica el apartado 3 de la regla de aprendizaje):

- $W_1 = W_1 + C = 0 + 1 = 1$
- $W_2 = W_2 + C = 0 + 1 = 1$
- $W_0 = W_0 + C = 0 + 1 = 1$

Y se continuaría de esta manera hasta terminar el entrenamiento, en cuyo caso obtendríamos los siguientes pesos sinápticos ajustados:



Peso sináptico	Valor
$W_1$	1
$W_2$	2
$W_0$	-2

### 2.3.7 Validación

Así mismo es importante realizar una validación cruzada para obtener una medida de la calidad del modelo. En este sentido, los datos disponibles (patrones) se deben disponer en dos partes: una parte destinada al entrenamiento de la red y la otra parte a la comprobación. El entrenamiento es usualmente medido en épocas, el número de presentaciones del conjunto de entrenamiento a la red.

Cuando el error de comprobación es mucho mayor que el error de entrenamiento, entonces se produce un problema de sobreajuste durante el proceso de entrenamiento. En realidad, ambos errores deberían ser similares, lo cual indica que se han capturado las tendencias reales del modelo.

Típicamente cuando el número de épocas de entrenamiento se incrementa, veremos los siguientes gráficos, independientemente del tipo de modelo de ANN.



.....

F

Épocas de entrenamiento

Figura

9. Errores de prueba y entrenamiento como una función de las épocas de entrenamiento

El error del conjunto de entrenamiento, mide cuán bien la ANN modela los datos. Debido a que nunca entrenamos sobre el conjunto de datos de prueba y los términos de error son no correlacionados, el error del conjunto de prueba es una medida de que tan bien el modelo sigue el patrón  $F$  o generaliza los conjuntos de datos. En la sección A del gráfico, el error del conjunto de prueba comienza a aprender el patrón de la serie de tiempo, indicado por el error decreciente. En  $Z$  épocas, el error del conjunto de prueba es mínimo-la red ANN ha encontrado la función  $F$  en su nivel óptimo. Más allá de éste mínimo, en la sección B, el error del conjunto de entrenamiento continúa decreciendo, mientras que error del conjunto de prueba se incrementa. Este hecho se explica porque al inicio la red se adapta progresivamente al conjunto de aprendizaje, adaptándose al problema y mejorando la representación, luego en un momento dado, el sistema se ajusta demasiado a las particularidades de los patrones empleados en el entrenamiento, captando incluso el “ruido” en ellos presente, de manera que el error que comete ante patrones diferentes a los empleados en el entrenamiento comienza a crecer, produciéndose el sobre aprendizaje o sobre ajuste. Del Brio, M., Sanz A. (2002).

### **2.3.8 Análisis de las series de tiempo utilizando una red neuronal**

Teniendo en cuenta que el objetivo principal del estudio de las series de tiempo es el pronóstico, entonces antes de seleccionar un método se debe tener en cuenta la forma cómo éste va ha ser utilizado, que precisión se espera de los pronósticos, cuál es la disponibilidad de recursos computacionales, la cantidad de datos disponibles y que tan lejos se va a pronosticar. Además algunos métodos de pronóstico producen sólo pronósticos puntuales, sin embargo en algunos casos es deseable obtener pronósticos en intervalos. A diferencia de los métodos tradicionales, las redes neuronales necesitan una “reducida” cantidad de datos para pronosticar el futuro de la serie; basadas en estos datos, los parámetros de la red son afinados usando un algoritmo de aproximación.

La racionalidad para el uso de redes neurales en el pronóstico de las series de tiempo, es, a partir de información histórica de la serie, construir un modelo, que permita predecir valores futuros de ésta información.

En términos formales, una serie de tiempo es una secuencia de vectores, que dependen del tiempo:  $\vec{x}(t), t = 0, 1, \dots$  Teóricamente,  $\vec{x}(t)$  puede ser vista como una función continua de la variable temporal  $t$ . Para propósitos prácticos, sin embargo, la variable temporal, es vista en término de pasos discretos del tiempo, conduciendo a una instancia del tiempo, en cada intervalo de tiempo fijo. El tamaño del intervalo del tiempo, depende de la naturaleza del problema y de la disponibilidad de los datos y puede ser periodos de milisegundos, horas, días, meses, trimestres o años.

En el problema del pronóstico, formalmente, se trata de encontrar  $\hat{\vec{x}}(t + d) = \mathbf{F}(\vec{x}(t), \vec{x}(t - 1), \dots, \epsilon_t)$ , donde  $d$  es llamado el intervalo para el pronóstico y la función  $\mathbf{F}$ , representa el patrón subyacente determina a la serie  $\vec{x}$ , tan cerca como sea posible, mientras que  $\epsilon_t$  es el error de medida o residual de los datos.

## 2.4 FORMULACIÓN DE LA HIPÓTESIS

### 2.4.1 Hipótesis general

La utilización de las redes neuronales permite elaborar un modelo de pronóstico de la inflación en el Perú, con la información de los últimos 10 años.

### 2.4.2 Hipótesis específica

1. La inflación en el Perú corresponde a una serie de tiempo no estacionaria.
2. Mediante el uso de las redes neuronales realiza pronósticos significativos en el periodo de Enero 2008 a Diciembre 2017.

## 2.5 OPERACIONALIZACIÓN DE VARIABLES E INDICADORES

VARIABLE INDEPENDIENTE : tiempo mensual de la inflación

VARIABLE DEPENDIENTE : la inflación

## 2.6 MARCO CONCEPTUAL

**Modelo no lineal: Modelo Neuronal.** Los modelos basados en redes neuronales artificiales (RNA) son una forma de computación inspirada en modelos biológicos con gran capacidad para aprender de la experiencia, generalizar de casos pasados a casos nuevos, abstraer características esenciales a partir de entradas, que representan información muchas veces irrelevante, etc.; en base a ello existe un gran número y variedad de aplicaciones en distintas áreas del conocimiento como: economía, finanzas, medio ambiente, etc.

Muchas de estas aplicaciones, tienen por objetivo principal pronosticar para periodos futuros el comportamiento de la variable en estudio (serie temporal) en función a su pasado y/o de otras variables que puedan explicar dicho comportamiento; para ello existen diversos métodos de análisis de predicción de series temporales; tales como, los modelos econométricos de Box

Jenkins cuyo objetivo es encontrar un modelo lineal representativo de la estructura determinista o estocástica, contenida en la serie, en los últimos años las RNA's han construido un gran avance en la modelación no lineal de series temporales.(Hidalgo y Cárcamo 2011).

## **Red Neuronal**

### **Definición.-**

Son un paradigma de aprendizaje y procesamiento automático inspirado en la forma en que funciona el sistema nervioso de los animales. Se trata de un sistema de interconexión de neuronas en una red que colabora para producir un estímulo de salida. En inteligencia artificial es frecuente referirse a ellas como redes de neuronas o redes neuronales.

Las redes neuronales son un elemento importante de las denominadas tecnologías de Inteligencia Artificial (IA). La IA es "la disciplina científica y técnica que se ocupa del estudio de las ideas que permiten ser inteligentes a los ordenadores" (definición de H. Winston).

Otra posible definición de la IA sería: rama de la computación que se encarga, entre otras cosas, de los problemas de percepción, razonamiento y aprendizaje en relación con sistemas artificiales, y que tiene como áreas de investigación a los sistemas expertos y de conocimiento, la robótica, los lenguajes naturales y las redes neuronales. Y a pesar de que el objetivo final de la IA, dotar de auténtica inteligencia a las máquinas, queda todavía muy lejos (e incluso hay autores que defienden que esto nunca será posible), la ciencia de la Inteligencia Artificial ha generado numerosas herramientas prácticas, entre las que se encuentran las redes neuronales.

## **CAPITULO III: MARCO METODOLOGICO**

### **3.1 ENFOQUE Y DISEÑO DE LA INVESTIGACIÓN**

El presente trabajo de investigación presenta un enfoque cuantitativo y un diseño no experimental, longitudinal y explicativo, investigación no experimental es aquella que se realiza sin manipular deliberadamente variables. Hernández, Fernández y Baptista (2003)

Cuyo esquema es el siguiente:

$$Y \text{ ----- } X$$

Dónde:

Y: inflación

X: tiempo mensual de la inflación

### **3.2 NIVEL Y TIPO DE LA INVESTIGACIÓN**

El presente trabajo de investigación presenta un nivel Longitudinal porque la información se toma en diversos periodos de tiempo. Además la información es de tipo aplicada. Este tipo de investigación es el que recolecta datos a través del tiempo en puntos o períodos especificados, para hacer inferencias respecto al cambio, sus determinantes y consecuencias. Hernández, Fernández y Baptista (2003).

### **3.3 POBLACIÓN Y MUESTRA DE LA INVESTIGACIÓN**

#### **3.3.1 Población**

La población está conformada por la serie temporal infinita, desde el 01 de enero de 1949 hasta la actualidad.

#### **3.3.2 Muestra.**

Lo conformará un total de 120 índices de la inflación, desde enero de 2008 hasta diciembre del 2017.

### **3.4 TÉCNICAS E INSTRUMENTOS DE INVESTIGACIÓN**

Fuente Indirecta: Revisión de documentos y archivos sobre la inflación y redes neuronales.

### 3.5 TÉCNICAS PARA EL PROCESAMIENTO DE DATOS

La información recolectada fue procesada mediante software estadístico IBM SPSS versión 20.0, Statgraphics versión 5.1, EVIEWS y software de redes neuronales donde se realizaron tablas y gráficos respectivos. Previamente a la elaboración del modelo usando las redes neuronales, se realizó un análisis descriptivo del comportamiento de la inflación, así como se evaluó si la serie es estacionaria, requisito para que la red neuronal converja a una solución satisfactoria.

### 3.6 METODOLOGÍA PARA PREDICCIÓN DE UN MODELO UNIVARIABLE CON REDES NEURONALES

A continuación se especifican los pasos a seguir para construir, entrenar y probar una red neuronal para predecir valores futuros de una serie de tiempo, basada únicamente en sus valores pasados:

1. Escalamiento de los datos
- Transformar los datos comprendidos entre 0 y 1, utilizando la siguiente fórmula:

$$z_t = \frac{y_t - Min}{Max - Min}$$

Dónde:

$y_t$ : son los valores originales de la serie de tiempo

Min: valor mínimo de la serie de tiempo

Max: valor máximo de la serie de tiempo

$Z_t$ : serie de tiempo transformada en los valores entre 0 y 1

1. Patrones de Entrenamiento y Prueba

Los valores de la serie de tiempo se dividen en dos conjuntos de datos:

- Patrones de entrenamiento: Está formado por el 80% de los datos de la serie. Se seleccionan en forma consecutiva y ordenada. Este conjunto de datos es el que se utilizará para el entrenamiento de la red neuronal.
- Patrones de prueba: Está formado por el 20% de los datos de la serie. Corresponden a los datos restantes, una vez que se han seleccionado los patrones de entrenamiento. Este conjunto de datos se utiliza para evaluar la capacidad de generalización o predicción de la red.

## 2. Topología de la RN

- Dirección de la información: Alimentación adelantada
- Tipo de interconexión: Totalmente conectada
- N° de entradas:  $p + 1$  (una constante de valor 1, denominada sesgo o intercepto)
- N° de capas ocultas: 1
- N° de nodos en la capa oculta:  $q$
- N° de salidas: 1
- Función de activación de la salida: logística

## 3. Determinación de las entradas ( $p$ )

Pueden considerarse varias recomendaciones que ayudaran en la selección de las entradas a la RNA:

- La periodicidad de los datos: Como en esta investigación se utilizan únicamente series de tiempo mensuales, es lógico pensar en considerar 12 o 13 retrasos. Podría ser conveniente construir una primera red con 13 entradas, correspondientes a los 13 retrasos y analizar los pesos, de manera que se seleccionen las entradas asociadas a los pesos de mayor magnitud, como lo sugiere Faraway y Chatfield (1998). Este análisis de los pesos ayuda a identificar las variables de entrada más importantes.
- Una vez determinado el modelo ARIMA, seleccionar como entradas a los valores correspondientes a los retrasos de  $y_t$  involucrados en este modelo.
- Otra herramienta que podría considerarse son los correlogramas simple y parcial de la serie estacionaria. Las entradas a la red serían los datos correspondientes a los retrasos que resultaran con una correlación significativamente diferente de cero.
- Prueba por ensayo y Error: Otras pruebas pudieran ser de interés, por ejemplo, considerar los datos retrasados 1, 4, 8, 12 periodos, 1, 3, 6, 9, 12 periodos, o 1, 2, 3, 4 periodos.

## 4. Determinación del número de nodos de la capa oculta ( $q$ )

- Una regla ad hoc, que en experimentos previos ha resultado de utilidad, es asumir que el valor inicial del número de nodos de la capa oculta sea igual al promedio entre el número de entradas y salidas, es decir:  $(\# \text{ Entradas} + \# \text{ Salidas})/2$  (si el valor obtenido es decimal se redondea).
- Pueden realizarse pruebas por ensayo y error, agregando más nodos, y comparando los errores y predicción.

## 5. Algoritmo de Entrenamiento: Retropropagación

## 6. Selección de los pesos iniciales

La escogencia de los pesos iniciales puede ser crucial y es recomendable probar con diferentes conjuntos de valores iniciales para tratar de obtener buenos resultados. Los pesos iniciales se generan aleatoriamente 50 veces (Faraway y Chatfield, 1998). Se selecciona el modelo que obtenga el menor promedio entre la suma de cuadrados de los errores de ajuste y predicción.

## 7. Entrenamiento de la RN seleccionada

- Para entrenar la red es necesario establecer los siguientes parámetros:
- El número máximo de ciclos y el error permitido de convergencia se fijará por ensayo y error
- Tasa de Aprendizaje, incremento de la tasa de aprendizaje y momento pueden ser fijados en 0.05, 1.05 y 0.95. Es conveniente realizar pruebas cambiando estos valores, y evaluando el comportamiento de los errores de entrenamiento y generalización.
- Una vez definida la RNA, con su ecuación se generan los valores de la serie de tiempo ajustada o producida por la red, utilizando los patrones de entrenamiento.
- Se calcula el error de entrenamiento

## 8. Predicción

- Usando la ecuación de predicción definida por la RNA se obtiene el valor de predicción  $t + 1$ . Para hacer predicciones más allá del periodo  $t + 1$ , se utiliza ésta como entrada para producir la predicción  $t + 2$  y así sucesivamente para todo el conjunto de predicción.
- Cálculo del error de generalización.

## 9. Comparación entre RNA con diferentes entradas

Mediante el error de entrenamiento y de generalización se compararan las RNA generadas y se selecciona aquella en la que ambos valores sean mínimos. No es conveniente que el error de entrenamiento sea muy pequeño en comparación con el error de generalización, pues esto indica un sobreajuste o memorización. La correlación entre los valores originales de la serie y los estimados por la RNA puede usarse como una medida de la exactitud de la predicción.



## CAPITULO IV: RESULTADOS Y DISCUSIÓN

### 4.1 SERIE DE LA INFLACIÓN: CASO UNIVARIABLE

#### 4.1.1 Redes Neuronales

Se sigue la metodología especificada en el capítulo III, sección 3.6. Para predecir valores futuros de la serie de tiempo de la INFLACIÓN, basándose en ciertos valores pasados. Se utilizó el paquete del paquete estadístico SPSS ® 21.0 de SPSS INC. Para desarrollar todas las rutinas computacionales, entrenamiento y prueba de las RN (ver anexo 3).

#### 1. Escalamiento de los datos

Todos los datos de la serie son transformados a valores entre 0 y 1, mediante una rutina computacional descrita en el anexo 3.

#### 2. Patrones de Entrenamiento y Prueba

Los valores de la serie de tiempo están comprendidos entre enero de 2008 y diciembre del 2017, lo que equivale a 10 años. Estos datos se dividen en dos conjuntos:

- Patrones de entrenamiento: Enero 2008 – septiembre 2014. Comprende 81 meses (6.9 años) que equivale al 67.5% de los datos.
- Patrones de Reserva: Octubre 2014 – Diciembre 2017. Comprende 39 meses (3.3 años) que equivale al 32.5% de los datos.

**Tabla 1. Resumen de procesamiento de casos**

**Resumen del procesamiento de los casos**

		N	Porcentaje
Muestra	Entrenamiento	81	67,5%
	Reserva	39	32,5%
Válidos		120	100,0%
Excluidos		0	
Total		120	

#### 3. Topología de la RN

Todas las RN que serán probadas son de alimentación adelantada, totalmente conectadas, con una capa oculta, un nodo adicional tanto en la capa de entrada como en la capa oculta de valor

constante 1 (sesgo) y función de activación logística en los nodos de la capa oculta y en el nodo de salida.

**Tabla 2. Información sobre la red**

**Información sobre la red**

Capa de entrada	Factores	1	Mes
	Covariables	1	Año
	Número de unidades <sup>a</sup>		12
	Método de cambio de escala para las covariables		Tipificados
Capas ocultas	Número de capas ocultas		1
	Número de unidades de la capa oculta 1 <sup>a</sup>		2
	Función de activación		Tangente hiperbólica
	Variables dependientes	1	Inflación
Capa de salida	Número de unidades		1
	Método de cambio de escala para las dependientes de escala		Tipificados
	Función de activación		Identidad
	Función de error		Suma de cuadrados

a. Sin incluir la unidad de sesgo

#### 4. Resumen del modelo

El resumen del modelo muestra información sobre los resultados y aplicar la red final a la muestra reservada.

- La suma de cuadrados del error se muestra porque la capa de resultados usa la función de activación softmax. Ésta es la función de error que la red intenta minimizar durante el entrenamiento.
- El error relativo de pronósticos incorrectos.
- El algoritmo de estimación se ha detenido ya que ha alcanzado el número máximo de épocas.

Lo ideal es que el entrenamiento se detenga, puesto que el error ha convergido. Esto plantea cuestionar sobre si se ha producido algún error durante el entrenamiento, y se debe tener en cuenta al realizar una inspección adicional de los resultados.

**Tabla 3. Resumen del modelo**

Resumen del modelo		
Entrenamiento	Suma de errores cuadráticos	14,038
	Error relativo	,351
	Regla de parada utilizada	Número máximo de épocas (100) superado
	Tiempo de entrenamiento	0:00:00.05
	Reserva Error relativo	1,757

Variable dependiente: Inflación

## 5. Ejecución del análisis

**Tabla 4. Resumen de procesamiento de casos para el modelo con muestra de prueba**

Resumen de procesamiento de casos		
	N	Porcentaje
Entrenamiento	56	47,7%
Muestra Prueba	25	19,8%
Reserva	39	31,7%
Válido	120	100,0%
Excluido	0	
Total	120	

De los 81 casos que se habían asignado originalmente a la muestra de entrenamiento, 25 se ha vuelto a signar a la muestra de prueba.

## 6. Algoritmo de entrenamiento: Las RN se entrenan con el algoritmo de retropropagación.

**Tabla 5. Información sobre la red**

Información de red		
Capas de entrada	Factores	1
		2
Capas ocultas	Número de unidades	27
	Número de capas ocultas	1
	Número de unidades de la capa oculta 1ª	2

	Función de activación	Tangente hiperbólica
	Variables dependientes	1
	Número de unidades	1
Capas de salida	Rescaling Method for Scale Dependents	Standardized
	Función de activación	Identity
	Función de error	Suma de cuadrados

a. Excluding the bias unit

El único cambio de la tabla de información de red es que la selección de arquitectura automática ha elegido veintisiete unidades de la capa oculta.

**Tabla 6. Resumen del modelo**

**Resumen del modelo**

	Suma de cuadrados del error	30.64%
	Error relativo de pronósticos incorrectos	6.3%
Entrenamiento	Regla de parada utilizada	1 pasos consecutivos sin disminución del error <sup>a</sup>
	Tiempo de entrenamiento	0:00:00.05
Prueba	Suma de cuadrado del error	86.8%
	Error relativo de pronósticos incorrectos	6.9%
Reserva	Error relativo de pronósticos incorrectos	10.6%

Variable dependiente: Inflación


a. Los cálculos del error se basan en la muestra de prueba.

El resumen del modelo muestra un par de signos positivos:

- El porcentaje de pronósticos incorrectos es prácticamente igual en las muestras reservadas, de entrenamiento y de prueba.
- El algoritmo de estimación se detuvo debido a que el error no disminuyó después de realizar un paso en el algoritmo.

Esto sugiere que, en efecto, el modelo original pudiera estar sobreentrenado y el problema se resolviera al agregar una muestra de prueba. Por supuesto, el tamaño de la muestra es relativamente pequeño y puede que no debamos sacar demasiadas conclusiones a partir de unos cuantos puntos de porcentaje.


## 1. Gráficos de pronosticados por observados



**Figura 10. Gráfico de pronosticados por observados para la inflación**

En el caso de las variables dependientes de escala, el gráfico de pronosticados por observados muestra un diagrama de dispersión con los valores pronosticados en el eje Y y los valores observados en el eje X para las muestras de entrenamiento y prueba combinadas. Lo ideal es que los valores estuvieran situados a lo largo de una línea de 45 grados que partiese del origen. Al examinar el gráfico, vemos que la red pronostica razonablemente bien la inflación. La tendencia general del gráfico no se aparta de la línea ideal de 45 grados en el sentido de que los pronósticos de la inflación tienden a estimar la baja de la inflación.

## 2. Gráficos de residuos por pronosticados



**Figura 11. Gráfico de residuos por pronosticados para la Inflación**


El gráfico de residuos por pronosticados muestra un diagrama de dispersión de los residuos (el valor observado menos el valor pronosticado) en el eje Y y los valores pronosticados en el eje X. Cada línea diagonal de este gráfico corresponde a una línea vertical del gráfico de pronosticados por observados y se puede ver con mayor claridad la progresión desde la predicción a la alza hasta la predicción a la baja a medida que disminuye la inflación observada.

### 3. Importancia de las variables independientes

La importancia de una variable independiente es una medida que indica cuánto cambia el valor pronosticado por el modelo de la red para diferentes valores de la variable independiente. La importancia normalizada es el resultado de los valores de importancia divididos por los valores de importancia mayores expresados como porcentajes.

**Tabla 7. Importancia de las variables independientes**

<b>Importancia de las variables independientes</b>		
	Importancia	Importancia normalizada
Mes	,345	52,7%
Año	,655	100,0%



**Figura 12. Gráfico de la importancia de las variables independientes**

#### 4. Ajuste o entrenamiento de la RN

- Fijación de los parámetros:
  - Número máximo de épocas: 2000
  - Error permitido de Convergencia: 0,01
  - Tasa de Aprendizaje: 0,01
  - Incremento en la tasa de aprendizaje: 1,05
  - Momento: 0,95

Se hicieron pruebas variando estos parámetros, en general, se encontraron las menores sumas de cuadrados de los errores de entrenamiento y generalización con estos valores.

- Con la ecuación general de cada una de las cinco RN se generan los valores de la serie ajustada, utilizando las entradas de los patrones de entrenamiento.

#### 5. Predicción

Por medio de la ecuación general de cada una de las RN se generan las predicciones para la serie de tiempo, utilizando las entradas de los patrones de prueba.

## 4.2 DISCUSIÓN

Se comparó con el estudio Lavanda (2010) sobre determinantes de la inflación, por lo que es concluyente que puede utilizarse la metodología redes neuronales para análisis de pronósticos con mayor cantidad de datos y el modelo se ajustara correctamente.

De esta manera utilizar una herramienta de procesamiento de datos, considerando como entradas los retrasos involucrados en el modelo proporcionado por esta metodología. Las herramientas muy útiles resultaron ser los gráficos de pronósticos por observados para la inflación ya que al observar pronostica razonablemente la inflación puesto que no se aparta de la línea ideal de 45 grados.

## **CAPITULO V: CONCLUSIONES Y RECOMENDACIONES**

### **5.1 CONCLUSIONES**

- Mediante la utilización de redes neuronales se han obtenido los valores mensuales pronosticados de la inflación a partir de información histórica contenida del año 2008 al 2017 para valores futuros del periodo Enero 2018 a Diciembre 2018.
- Se obtuvo la base de datos de los valores mensuales de la inflación en el periodo enero-2008 a diciembre-2017, a partir de ellos se aplicó los métodos de pronóstico mediante Redes Neuronales.
- Al someter la serie de tiempo al análisis adecuado se confirma que si satisface los supuestos que se requiere para la aplicación de las redes neuronales, de la suavización exponencial corregida de la tendencia.
- Se pronosticaron los valores futuros de la inflación para el periodo enero-2018 hasta diciembre-2018 con sus respectivos intervalos de predicción al 95 % para cada uno de ellos.

### **5.2 RECOMENDACIONES**

Una mayor experimentación con nuevos casos de estudio podría ser recomendable para corroborar lo expuesto en la sección anterior.

El algoritmo de aprendizaje utilizado es el muy conocido algoritmo de retro propagación, pero sería de mucho interés experimentar con nuevos algoritmos y modelos de red que pudieran ser útiles para predicciones con series de tiempo, tales como la RN función de base radial y la red neurodifusa. Esto permitiría establecer comparaciones entre diferentes tipos de redes y probablemente mejorar las predicciones.

Debido a la experiencia necesaria la creación de un sistema experto que ayude a identificar las entradas más adecuadas para la red, mediante el uso de los correlogramas simple y parcial, el número de capas ocultas y sus nodos, en fin, todos los aspectos que involucra el diseño de una RN para predicción con series de tiempo.



## CAPITULO VI: REFERENCIAS BIBLIOGRAFICAS

- **Alonso, G. & Becerril, J.L.** (1993). Introducción a la inteligencia artificial. Ed. Multimedia. Ediciones S.A. Barcelona.
- **Araujo, E & Gama, C** (2004). “Replicando características de ciclos económicos: un estadio comparativo entre Redes Neuraish Artificiais e modelos ARIMA” IBMEC.
- **Aristizábal, M** (2006). “Evaluación asimétrica de una red neuronal artificial: aplicación al caso de la inflación en Colombia”. Lecturas de Economía, Núm 65, Universidad de Antioquia.
- **Brown, D. & Rothery, P.** (1993). Models in Biology.Ed.Springer-Verlag.Berlín.
- **Camilo Santana J.** (2009). “Predicción de series temporales con redes neuronales. Una aplicación a la inflación Colombiana.” Universidad Federal de Pernambuco, Brasil.
- **Collantes, J. V.** (2001). “Predicción con redes neuronales: Comparación con las metodologías de Box y Jenkins”, Tesis de maestría. Universidad de los Andes.
- **Cybenko, G** (1989). “Approximation by Superpositions of a sigmoidal function”. Mathematics of Control Signals and Systems 2, 303-314.
- **DARPA Neural Network Study** (1988). AFCEA International Press, p. 60
- **Dutta, S. y Shekbar, S.** (1988). "Bond Rating: Una aplicación conservadora de las redes neuronales", Actas de la Conferencia Internacional IEEE sobre Redes Neuronales, pp. II443-II450.
- **Franses, P.,H. y van Dijk, D.** (2000). “Non-linear Time Series Models in Empirical Finance”.Cambridge University Press.
- **FlrezL Pez Raquel y José M. Fernández Fernández** .Las Redes Neuronales Artificiales.

- **Felipe Larraín B. / Jeffrey D. Sachs.** (2002). Macroeconomía en la economía global. 2da edición, Editorial Indugraf S.A. Buenos Aires – Argentina.
- **Garcia, I.** (2003). “Análisis y predicción de la serie de tiempo del precio externo del café colombiano utilizando redes neuronales artificiales”, Revista de la facultad de ciencias, Pontificia Universidad Javeriana, vol. 8, pp. 45-50.
- **Guerrero, V.** (2003). “Análisis estadístico de series de tiempo económicas”. Thomson editores, segunda edición.
- **Gujarati, D. N.** (2004). Econometría, (4ª. Ed.), México: Mc Graw-Hill, pp. 771-780.
- **Haykin, S.** (1994). "Neural Networks: A Comprehensive Foundation." NY, MacMillan, p.2
- **Hawley, D. et al.** (1990). "Los sistemas neuronales artificiales. Una nueva herramienta para la toma de decisiones financieras ", Diario Los analistas financieros, pp. 90-113.
- **Hendry, David** (1995) “Dynamic Econometrics”. Oxford University Press.
- **Hernández, S., Fernandez, C. & Baptista, P.** (2006). Metodología de la investigación (4ta Ed.). México: Mc Graw Hill.
- **Hilero, José R., y Martínez Victor J.** (2000). Redes Neuronales artificiales. 2000. Editorial Alfa omega . Madrid.- España.
- **Hill, T., O’Connor, M. y Remus, W.** (1996). "Modelos de red neuronal para pronósticos de series de tiempo", Gestión de la ciencia, 42, 7, pp. 1082-1092.
- **Jalil, M. A. y Misas, M.** (2005). “Evaluación de pronósticos del tipo de cambio utilizando redes neuronales y funciones de pérdida asimétrica”. Borradores de Economía, Núm 376, Banco de la República-Colombia
- **Kohonen, T.** (1988). "An introduction to Neural Computing". Neural Networks, Vol.1, pp.3-16
- **Kuan C. M. and H. White** (1994). “Artificial Neural Networks: An Econometric Perspective”. Econometric Reviews

▪ **Mate c. Universidad Pontificia. Icai-Icade Comillas. Madrid.**

Disponible en: [www.upcomillas.es/presim/documentos/pred\\_clasi\\_03pdf](http://www.upcomillas.es/presim/documentos/pred_clasi_03pdf).

▪ **Medeiros, M., Veiga, A. y Pedreira, C. (2001).** "Las tasas de modelado de cambio: transiciones suaves, Redes Neuronales y Modelos Lineales", IEEE Transactions on Neural Networks, vol. 12, no. 4, julio, pp. 755-764.

▪ **Misas, M. A., E., Arango, C. A. y Hernández, N. (2003).** "La demanda de efectivo en Colombia: una caja negra a la luz de las redes neuronales". Borradores de Economía, Núm.268, Banco de la República.

▪ **Misas, M. A., López, E. y Querubín, P. (2002).** "La Inflación en Colombia: una aproximación desde las redes neuronales". Borradores de Economía, Núm.199, Banco de la República.

▪ **Montenegro, Álvaro (2001).** "Redes Neurales Artificiales". Documentos de Economía, 2001-11. Pontificia Universidad Javeriana.

▪ **Peña, D (2005).** "Análisis de series temporales". Alianza Editorial, Madrid.

▪ **Pindyck, R. Rubinfeld, D. (2001).** Econometría: Modelos y Pronósticos. Cuarta edición. McGraw Hill. Mexico, DF.

▪ **P. H. Winston .**"Inteligencia Artificial" Tercera Ed. Addison-Wesley Iberoamericana, 1.994

▪ **Rubiños C. y Salas J. (2005).** La realidad del crecimiento en el Perú. Universidad del Pacífico de Lima.

▪ **Salazar Sáenz J. (2009).** "Evaluación de pronóstico de una red neuronal sobre el PIB en Colombia. Pontificia Universidad Javeriana.

▪ **Shang-Wu, Y. (1999).** "Predecir y Arbitraje de la Futura Bolsa de Tokio: Una Aplicación de Redes de retropropagación", de Asia y el Pacífico, los Mercados Financieros, pp. 341-354.

▪ **Tkacz, G. y Hu, S. (1999).** "El pronóstico de crecimiento del PIB usando redes neuronales artificiales". Documento de trabajo de pag.99-3, del Banco de Canadá.

- **Torres, José Luis** (2006) “Modelos para la inflación básica de bienes transables y no transables en Colombia”. Borradores de Economía, Núm. 365, Banco de la República.
  
- **Ulbritch, C.** (1995). "La formación del Estado en las redes neuronales para el Manejo de la información temporal", Tesis Doctoral, Instituto für Med.Kybernetik u. AI, Univeristy de Viena.
  
- **White, H.** (1988). "La predicción económica a través de las redes neuronales: el caso de los retornos diarios acciones de IBM", Conferencia Internacional IEEE sobre Redes Neuronales, EE.UU., pp. 451-459.
  
- **Zhang, G. P. y Berardi, V. L.** (2001). "Predicción de series temporales con los ensambles de redes neuronales: una aplicación para la predicción del tipo de cambio", Revista de la sociedad de la investigación operativa, pp. 652-664.
  
- **WEBGRAFIA**  
**Redes Neuronales**  
[http://members.tripod.com/jesus\\_alfonso\\_lopez/RnaIntro.html](http://members.tripod.com/jesus_alfonso_lopez/RnaIntro.html) Redes neuronales de James A. Freeman y David M. Skapura.

## ANEXOS

### ANEXO 1

**TABLA A1 VALORES ORIGINALES DE LA INFLACIÓN, LA PREDICCIÓN RN Y EL ERROR**

Año	Mes	Inflación	Predicción	Error
2016	1	2.2	2.1	0.1
2016	2	2.2	2.2	0
2016	3	2.1	2.2	-0.1
2016	4	2.2	2.1	0.1
2016	5	2.1	2.1	0
2016	6	2.0	2.2	-0.2
2016	7	1.9	2.1	-0.2
2016	8	1.8	2.1	-0.3
2016	9	2.1	2.1	0
2016	10	2.2	2.1	0.1
2016	11	2.2	2.2	0
2016	12	2.2	2.2	0
2017	1	2.6	2.1	0.5
2017	2	2.1	2.1	0
2017	3	2.0	2.1	-0.1
2017	4	2.0	2.1	-0.1
2017	5	2.0	2.0	0
2017	6	1.7	2.1	-0.4
2017	7	1.7	2.1	-0.4
2017	8	2.0	2.0	0
2017	9	2.0	2.1	-0.1
2017	10	2.0	2.0	0
2017	11	2.1	2.1	0
2017	12	2.1	2.1	0
2018	1	1.9	2.0	-0.1
2018	2	2.3	2.0	0.3
2018	3	2.1	2.1	0
2018	4	2.0	2.0	0
2018	5	2.1	2.0	0.1
2018	6	2.3	2.1	0.2
2018	7	2.4	2.0	0.4
2018	8	2.4	2.0	0.4
2018	9	2.4	2.1	0.3
2018	10	2.5	2.0	0.5
2018	11	2.2	2.1	0.1
2018	12	1.9	2.1	-0.2

## ANEXO 2

**TABLA A2 VALORES ORIGINALES DE LA INFLACIÓN, LA PREDICCIÓN CON SUS RESPECTIVOS INTERVALOS AL 95%.**

Año	Mes	Inflación	Predicción	L. I. 95%	L.S. 95%
2018	1	1.9	2.18	1.48	3.19
2018	2	2.3	2.04	1.01	4.09
2018	3	2.1	1.99	0.75	5.27
2018	4	2.0	1.95	0.57	6.63
2018	5	2.1	1.87	0.44	7.92
2018	6	2.3	2.00	0.33	8.65
2018	7	2.4	2.20	0.26	9.81
2018	8	2.4	2.10	0.24	12.55
2018	9	2.4	2.20	0.21	15.30
2018	10	2.5	2.30	0.19	18.19
2018	11	2.2	1.99	0.18	22.15
2018	12	1.9	1.99	0.16	25.22

## ANEXO 3

### Rutinas desarrolladas en SPSS para la predicción con RN

#### \*Semilla aleatoria

SET SEED=9191972.

#### \*Partición

DATASET ACTIVATE Conjunto\_de\_datos0.

COMPUTE partición=2\*rv.bernoulli(0.7)-1.

EXECUTE.

#### \*Multilayer Perceptron Network.

MLP Inflación (MLEVEL=S) BY AÑO\_MES\_

/PARTITION VARIABLE=partición

/ARCHITECTURE AUTOMATIC=YES (MINUNITS=1 MAXUNITS=50)

/CRITERIA TRAINING=BATCH OPTIMIZATION=SCALEDCONJUGATE

LAMBDAINITIAL=0.0000005

SIGMAINITIAL=0.00005 INTERVALCENTER=0 INTERVALOFFSET=0.5 MEMSIZE=1000

/PRINT CPS NETWORKINFO SUMMARY CLASSIFICATION

/PLOT NETWORK

/STOPPINGRULES ERRORSTEPS= 1 (DATA=AUTO) TRAININGTIMER=ON

(MAXTIME=15) MAXEPOCHS=AUTO

ERRORCHANGE=1.0E-4 ERRORRATIO=0.0010  
/MISSING USERMISSING=EXCLUDE .

\*Multilayer Perceptron Network.

MLP Inflación (MLEVEL=S) BY AÑO\_ MES\_

/PARTITION VARIABLE=partición

/ARCHITECTURE AUTOMATIC=YES (MINUNITS=1 MAXUNITS=50)

/CRITERIA TRAINING=BATCH OPTIMIZATION=SCALEDCONJUGATE

LAMBDAINITIAL=0.0000005

SIGMAINITIAL=0.00005 INTERVALCENTER=0 INTERVALOFFSET=0.5 MEMSIZE=1000

/PRINT CPS NETWORKINFO SUMMARY IMPORTANCE

/PLOT PREDICTED RESIDUAL

/STOPPINGRULES ERRORSTEPS= 1 (DATA=AUTO) TRAININGTIMER=ON

(MAXTIME=15) MAXEPOCHS=AUTO

ERRORCHANGE=1.0E-4 ERRORRATIO=0.0010

/MISSING USERMISSING=EXCLUDE .

\*Multilayer Perceptron Network.

MLP Inflación (MLEVEL=S) BY AÑO\_ MES\_

/PARTITION VARIABLE=partición

/ARCHITECTURE AUTOMATIC=YES (MINUNITS=1 MAXUNITS=50)

/CRITERIA TRAINING=BATCH OPTIMIZATION=SCALEDCONJUGATE

LAMBDAINITIAL=0.0000005

SIGMAINITIAL=0.00005 INTERVALCENTER=0 INTERVALOFFSET=0.5 MEMSIZE=1000

/PRINT CPS NETWORKINFO SUMMARY IMPORTANCE

/PLOT PREDICTED RESIDUAL

/SAVE PREDVAL

/OUTFILE MODEL='inflación'

/STOPPINGRULES ERRORSTEPS= 1 (DATA=AUTO) TRAININGTIMER=ON

(MAXTIME=15) MAXEPOCHS=AUTO

ERRORCHANGE=1.0E-4 ERRORRATIO=0.0010

/MISSING USERMISSING=EXCLUDE .

\*Multilayer Perceptron Network.

MLP Inflación (MLEVEL=S) BY AÑO\_ MES\_

/PARTITION VARIABLE=partición

/ARCHITECTURE AUTOMATIC=YES (MINUNITS=1 MAXUNITS=50)

```

/CRITERIA          TRAINING=BATCH          OPTIMIZATION=SCALEDCONJUGATE
LAMBDAINITIAL=0.0000005
  SIGMAINITIAL=0.00005 INTERVALCENTER=0 INTERVALOFFSET=0.5 MEMSIZE=1000
/PRINT CPS NETWORKINFO SUMMARY IMPORTANCE
/PLOT PREDICTED RESIDUAL
/SAVE PREDVAL
/OUTFILE MODEL='inflación'
/STOPPINGRULES    ERRORSTEPS=    1    (DATA=AUTO)    TRAININGTIMER=ON
(MAXTIME=15) MAXEPOCHS=AUTO
  ERRORCHANGE=1.0E-4 ERRORRATIO=0.0010
/MISSING USERMISSING=EXCLUDE .

```

\*Multilayer Perceptron Network.

MLP Inflación (MLEVEL=S) BY AÑO\_ MES\_

```

/PARTITION VARIABLE=partición
/ARCHITECTURE  AUTOMATIC=YES (MINUNITS=1 MAXUNITS=50)
/CRITERIA          TRAINING=BATCH          OPTIMIZATION=SCALEDCONJUGATE
LAMBDAINITIAL=0.0000005
  SIGMAINITIAL=0.00005 INTERVALCENTER=0 INTERVALOFFSET=0.5 MEMSIZE=1000
/PRINT CPS NETWORKINFO SUMMARY CLASSIFICATION IMPORTANCE
/PLOT PREDICTED RESIDUAL
/SAVE PREDVAL
/OUTFILE MODEL='inflación'
/STOPPINGRULES    ERRORSTEPS=    1    (DATA=AUTO)    TRAININGTIMER=ON
(MAXTIME=15) MAXEPOCHS=AUTO
  ERRORCHANGE=1.0E-4 ERRORRATIO=0.0010
/MISSING USERMISSING=EXCLUDE .

```